



**TUGAS AKHIR – SS141501**

**APLIKASI MODEL *HYBRID*  
*QUANTILE REGRESSION NEURAL NETWORK*  
PADA PERAMALAN PECAHAN *INFLOW* DAN  
*OUTFLOW* UANG KARTAL DI INDONESIA**

**PRILYANDARI DINA SAPUTRI  
NRP 1313 100 020**

**Dosen Pembimbing  
Dr. Suhartono  
Dr. rer. pol. Dedy Dwi Prastyo**

**PROGRAM STUDI SARJANA  
DEPARTEMEN STATISTIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2017**





**TUGAS AKHIR – SS141501**

***APLIKASI MODEL *HYBRID*  
QUANTILE REGRESSION NEURAL NETWORK  
PADA PERAMALAN PECAHAN *INFLOW* DAN  
*OUTFLOW* UANG KARTAL DI INDONESIA***

**PRILYANDARI DINA SAPUTRI  
NRP 1313 100 020**

**Dosen Pembimbing  
Dr. Suhartono  
Dr. rer. pol. Dedy Dwi Prastyo**

**PROGRAM STUDI SARJANA  
DEPARTEMEN STATISTIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2017**





**FINAL PROJECT – SS 141501**

**HYBRID QUANTILE REGRESSION  
NEURAL NETWORK MODEL FOR  
FORECASTING CURRENCY INFLOW AND  
OUTFLOW IN INDONESIA**

**PRILYANDARI DINA SAPUTRI  
NRP 1313 100 020**

**Supervisor  
Dr. Suhartono  
Dr. rer. pol. Dedy Dwi Prastyo**

**UNDERGRADUATE PROGRAMME  
DEPARTMENT OF STATISTICS  
FACULTY OF MATHEMATICS AND NATURAL SCIENCES  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2017**



## LEMBAR PENGESAHAN

### **APLIKASI MODEL *HYBRID* *QUANTILE REGRESSION NEURAL NETWORK* PADA PERAMALAN PECAHAN *INFLOW* DAN *OUTFLOW* UANG KARTAL DI INDONESIA**

#### **TUGAS AKHIR**

Diajukan Untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sarjana Sains  
pada

Program Studi Sarjana Departemen Statistika  
Fakultas Matematika dan Ilmu Pengetahuan Alam  
Institut Teknologi Sepuluh Nopember

Oleh :

**Prilyandari Dina Saputri**  
NRP. 1313 100 020

Disetujui oleh Pembimbing:

Dr. Suhartono

NIP. 19710929 199512 1 001

Dr. rer. pol. Dedy Dwi Prastyo


NIP. 19831204 200812 1 002



Mengetahui,

Kepala Departemen



  
Dr. Suhartono

NIP. 19710929 199512 1 001

SURABAYA, JULI 2017

*(Halaman ini sengaja dikosongkan)*



**APLIKASI MODEL *HYBRID***  
***QUANTILE REGRESSION NEURAL NETWORK***  
**PADA PERAMALAN PECAHAN *INFLOW* DAN**  
***OUTFLOW* UANG KARTAL DI INDONESIA**

**Nama Mahasiswa** : Prilyandari Dina Saputri  
**NRP** : 1313 100 020  
**Departemen** : Statistika  
**Dosen Pembimbing** : Dr. Suhartono  
Dr. rer. pol. Dedy Dwi Prastyo

**Abstrak**

*Regresi kuantil merupakan perluasan dari regresi Ordinary Least Square (OLS) yang dapat menjelaskan keterkaitan antar variabel pada berbagai kuantil. Regresi kuantil juga dapat digunakan dalam peramalan data runtun waktu. Penelitian ini bertujuan untuk memperoleh model peramalan inflow dan outflow tiap pecahan di Indonesia yang akurat dan dapat menangkap pola variasi kalender serta heteroskedastisitas. Untuk meningkatkan akurasi hasil peramalan, regresi kuantil dikombinasikan dengan neural network, yang dikenal sebagai quantile regression neural network (QRNN). Metode QRNN akan dibandingkan dengan metode ARIMAX dan neural network berdasarkan RMSE, MAE, MdAE, MAPE, dan MdAPE. Terdapat dua kajian dalam penelitian ini, yakni studi simulasi dan aplikasi pada 14 pecahan data inflow dan outflow di Indonesia. Studi simulasi menunjukkan bahwa QRNN dapat menangkap pola heteroskedastisitas dan nonlinieritas dibandingkan ARIMAX dan neural network. Sedangkan aplikasi pada data inflow dan outflow menunjukkan bahwa QRNN merupakan metode terbaik dalam meramalkan 10 dari 14 pecahan. Namun peramalan interval metode QRNN menunjukkan adanya crossing antar kuantil yang disebabkan oleh pengestimasi kuantil secara independen.*

**Kata Kunci :** *Inflow dan Outflow, Heteroskedastisitas, Neural Network, Nonlinieritas, Regresi Kuantil*

*(Halaman ini sengaja dikosongkan)*

# **HYBRID QUANTILE REGRESSION NEURAL NETWORK MODEL FOR FORECASTING CURRENCY INFLOW AND OUTFLOW IN INDONESIA**

**Name** : Prilyandari Dina Saputri  
**NRP** : 1313 100 020  
**Department** : Statistics  
**Supervisor** : Dr. Suhartono  
Dr. rer. pol. Dedy Dwi Prastyo

## **Abstract**

*Quantile regression was developed from Ordinary Least Square regression. Furthermore, quantile regression can explain the relationship between variables on various quantiles. Quantile regression can be applied in forecasting analysis. The aim of this study was to find the best model for forecasting inflow and outflow in Indonesia which can overcome heteroscedasticity and nonlinearity problem. In order to improve the accuracy of forecasting results, quantile regression will be combined with neural network method, known as quantile regression neural network (QRNN). QRNN will be compared with ARIMAX and neural network method based on RMSE, MAE, MdAE, MAPE, and MdAPE criteria. In this study, there are two main topics will be discussed, i.e simulation study and case study about 14 currencies of inflow and outflow data. Simulation study shows that QRNN is the best method to solve heteroscedasticity and nonlinearity problem. While, application in inflow and outflow data shows that QRNN is the best method to forecast 10 of 14 currencies. However, there is a crossing within quantile which can be caused by the estimates of each quantile that are calculated independently.*

**Keywords:** *Currency Inflow and Outflow, Heteroscedasticity, Neural Network, Nonlinearity, Quantile Regression*

*(Halaman ini sengaja dikosongkan)*

## KATA PENGANTAR

Puji syukur penulis panjatkan atas rahmat dan hidayah yang diberikan Allah SWT sehingga penulis dapat menyelesaikan laporan Tugas Akhir yang berjudul “**Aplikasi Model *Hybrid Quantile Regression Neural Network* pada Peramalan Pecahan Inflow dan Outflow Uang Kartal di Indonesia**” dengan lancar.

Penulis menyadari bahwa Tugas Akhir ini dapat terselesaikan tidak terlepas dari bantuan dan dukungan berbagai pihak. Oleh karena itu, penulis menyampaikan terima kasih kepada :

1. Dr. Suhartono dan Dr. rer. pol. Dedy Dwi Prastyo selaku dosen pembimbing Tugas Akhir, yang telah meluangkan waktu dan dengan sangat sabar memberikan bimbingan, saran, dukungan serta motivasi selama penyusunan Tugas Akhir.
2. Dr. Ismaini Zain, M.Si. dan Santi Puteri Rahayu, Ph.D. selaku dosen penguji yang telah banyak memberi masukan kepada penulis.
3. Dr. Suhartono selaku Ketua Departemen Statistika dan Dr. Sutikno, M.Si. selaku Ketua Program Studi Sarjana yang telah memberikan fasilitas, sarana, dan prasarana.
4. Dra. Destri Susilaningrum, M.Si. dan Dr. Purhadi, M.Sc. selaku dosen wali yang telah banyak memberikan saran dan arahan dalam proses belajar di Jurusan Statistika.
5. Ayah dan mama, atas segala do’a, nasehat, kasih sayang, dan dukungan yang diberikan kepada penulis demi kesuksesan dan kebahagiaan penulis, serta mbak Dian dan Dira, yang selalu menghibur dan memberi perhatian kepada penulis.
6. Semua pihak yang membantu dalam penyusunan Tugas Akhir

Besar harapan penulis untuk mendapatkan kritik dan saran yang membangun sehingga Tugas Akhir ini dapat memberikan manfaat bagi semua pihak yang terkait.

Surabaya, Juli 2017

Penulis

*(Halaman ini sengaja dikosongkan)*

# DAFTAR ISI

	Halaman
<b>HALAMAN JUDUL .....</b>	i
<b>COVER PAGE .....</b>	iii
<b>LEMBAR PENGESAHAN.....</b>	v
<b>ABSTRAK.....</b>	vii
<b>ABSTRACT .....</b>	ix
<b>KATA PENGANTAR .....</b>	xi
<b>DAFTAR ISI.....</b>	xiii
<b>DAFTAR GAMBAR .....</b>	xvii
<b>DAFTAR TABEL.....</b>	xxiii
<b>DAFTAR LAMPIRAN .....</b>	xxvii
<b>BAB I PENDAHULUAN .....</b>	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah .....	5
1.3 Tujuan.....	6
1.4 Manfaat.....	7
1.5 Batasan Masalah.....	7
<b>BAB II TINJAUAN PUSTAKA .....</b>	9
2.1 Analisis Deret Waktu .....	9
2.2 Model Regresi <i>Time Series</i> dengan Variasi Kalender .....	9
2.3 ACF dan PACF.....	10
2.4 <i>Autoregressive Integrated Moving Average</i> (ARIMA) .....	11
2.4.1 Identifikasi.....	12
2.4.2 Estimasi Parameter dan Uji Signifikansi.....	15
2.4.3 Cek Diagnosa .....	21
2.5 <i>Autoregressive Integrated Moving Average with</i> <i>Exogeneous Variable</i> (ARIMAX) .....	22
2.6 Model <i>Generalized Autoregressive Conditional</i> <i>Heteroscedasticity</i> (GARCH).....	23
2.7 <i>Quantile Regression</i> .....	24
2.7.1 Estimasi Parameter .....	25

2.7.2 Pengujian Signifikansi Parameter.....	27
2.8 <i>Neural Network</i> .....	27
2.9 <i>Quantile Regression Neural Network</i> .....	30
2.10 Evaluasi Model .....	31
2.11 <i>Inflow</i> dan <i>Outflow</i> Uang Kartal.....	33
2.12 Penyusunan Rencana Kebutuhan Uang di Bank Indonesia.....	34
<b>BAB III METODOLOGI PENELITIAN</b> .....	37
3.1 Sumber Data .....	37
3.2 Variabel Penelitian.....	37
3.3 Langkah Analisis .....	39
<b>BAB IV ANALISIS DAN PEMBAHASAN</b> .....	55
4.1 Studi Simulasi.....	55
4.1.1 Pembangkitan Data Simulasi.....	56
4.1.2 Peramalan dengan ARIMAX .....	64
4.1.3 Peramalan dengan <i>Neural Network</i> .....	70
4.1.4 Peramalan dengan <i>Hybrid Quantile Regression Neural Network</i> .....	79
4.1.5 Perbandingan model ARIMAX, <i>Neural Network</i> , dan <i>Quantile Regression Neural Network</i> data Simulasi.....	89
4.2 Karakteristik Data <i>Inflow</i> dan <i>Outflow</i> di Indonesia	94
4.3 Peramalan <i>Inflow</i> dan <i>Outflow</i> dengan ARIMAX...	103
4.4 Peramalan <i>Inflow</i> dan <i>Outflow</i> dengan <i>Neural Network</i> .....	116
4.5 Peramalan <i>Inflow</i> dan <i>Outflow</i> dengan <i>Quantile Regression Neural Network</i> .....	128
4.6 Perbandingan kebaikan model ARIMAX, <i>Neural Network</i> , dan <i>Quantile Regression Neural Network</i>	140
4.7 Peramalan Data <i>Inflow</i> dan <i>Outflow</i> Tahun 2017....	146
<b>BAB V KESIMPULAN DAN SARAN</b> .....	151
5.1 Kesimpulan .....	151
5.2 Saran .....	152



<b>DAFTAR PUSTAKA .....</b>	<b>155</b>
<b>LAMPIRAN.....</b>	<b>161</b>
<b>BIODATA PENULIS.....</b>	<b>251</b>

*(Halaman ini sengaja dikosongkan)*

## DAFTAR GAMBAR

	Halaman
<b>Gambar 2.1</b>	Arsitektur <i>Neural Network</i> ..... 29
<b>Gambar 3.1</b>	Diagram Alir Langkah-langkah Analisis.... 47
<b>Gambar 3.2</b>	Ilustrasi Pembentukan Model QRNN Satu Tahap ..... 48
<b>Gambar 3.3</b>	Ilustrasi Pembentukan Model QRNN dengan Dekomposisi..... 49
<b>Gambar 3.4</b>	Ilustrasi Pembentukan Model QRNN dengan <i>Input</i> berupa Prediksi NN..... 50
<b>Gambar 3.5</b>	Ilustrasi Pembentukan Model QRNN dengan <i>Input</i> berupa Prediksi NN dan <i>lag</i> $Y_t$ ..... 51
<b>Gambar 3.6</b>	Ilustrasi Pembentukan Model QRNN dengan <i>Input</i> Nilai Prediksi Metode TSR dan <i>lag</i> $Y_t$ ..... 52
<b>Gambar 3.7</b>	Ilustrasi Pembentukan Model QRNN dengan <i>Input</i> Nilai Prediksi Metode TSR dan <i>lag</i> $N_t$ ..... 53
<b>Gambar 4.1</b>	Pola untuk Dekomposisi <i>Pattern</i> . .... 58
<b>Gambar 4.2</b>	Plot <i>Noise</i> pada waktu ke- $t$ dengan <i>Noise</i> pada waktu ke $t-1$ untuk Pola Linier (a) dan Nonlinier (b). .... 60
<b>Gambar 4.3</b>	Plot <i>Time Series</i> Skenario 1..... 60
<b>Gambar 4.4</b>	Identifikasi Heteroskedastisitas dengan <i>Boxplot</i> ..... 61
<b>Gambar 4.5</b>	Plot <i>Time Series</i> Skenario 2..... 62
<b>Gambar 4.6</b>	<i>Boxplot</i> tanpa Tren dan Variasi Kalender untuk Skenario 2..... 62
<b>Gambar 4.7</b>	Plot <i>Time Series</i> Skenario 3..... 63
<b>Gambar 4.8</b>	<i>Boxplot</i> tanpa Tren dan Variasi Kalender untuk Skenario 3..... 63
<b>Gambar 4.9</b>	Plot <i>Time Series</i> Skenario 4..... 64
<b>Gambar 4.10</b>	<i>Boxplot</i> tanpa Tren dan Variasi Kalender untuk Skenario 4..... 64

<b>Gambar 4.11</b>	Perbandingan Data Aktual dan Ramalan Model ARIMAX untuk Simulasi Replikasi Pertama pada Skenario 1 (a), Skenario 2 (b), Skenario 3 (c), dan Skenario 4 (d).....	67
<b>Gambar 4.12</b>	Perbandingan Kriteria Evaluasi Model ARIMAX Data Simulasi.....	68
<b>Gambar 4.13</b>	Perbandingan RMSE Model ARIMAX Data Simulasi.....	69
<b>Gambar 4.14</b>	Perbandingan RMSE ARIMAX Data <i>Training-Testing</i> untuk Data Simulasi.....	69
<b>Gambar 4.15</b>	Perbandingan RMSE dalam Pemilihan <i>Input</i> Model <i>Neural Network</i> untuk Data Simulasi. ....	73
<b>Gambar 4.16</b>	Perbandingan RMSE dalam Pemilihan <i>Neuron</i> Model <i>Neural Network</i> untuk Data Simulasi. ....	74
<b>Gambar 4.17</b>	Perbandingan Data Aktual dan Ramalan Model <i>Neural Network</i> untuk Simulasi Replikasi Pertama pada Skenario 1 (a), Skenario 2 (b), Skenario 3 (c), dan Skenario 4 (d).....	76
<b>Gambar 4.18</b>	Perbandingan Kriteria Model <i>Neural Network</i> Data Simulasi. ....	77
<b>Gambar 4.19</b>	Perbandingan RMSE Model <i>Neural Network</i> untuk Data Simulasi. ....	78
<b>Gambar 4.20</b>	Perbandingan RMSE <i>Training-Testing</i> Model <i>Neural Network</i> untuk Data Simulasi. ....	79
<b>Gambar 4.21</b>	Perbandingan <i>Crossing</i> yang Model QRNN untuk Data Simulasi pada Data <i>Training</i> (a) dan <i>Testing</i> (b).....	80
<b>Gambar 4.22</b>	Perbandingan Rata-rata <i>Crossing</i> Model QRNN untuk Data Simulasi .....	82

<b>Gambar 4.23</b>	Perbandingan RMSE dan Banyaknya <i>Neuron</i> Model QRNN Data Simulasi untuk <i>Training</i> (a) dan <i>Testing</i> (b).....	83
<b>Gambar 4.24</b>	Perbandingan MdAE dan MdAPE Model QRNN untuk Data Simulasi. ....	84
<b>Gambar 4.25</b>	Perbandingan Kriteria Model <i>Quantile Regression Neural Network</i> untuk Data Simulasi. ....	87
<b>Gambar 4.26</b>	Perbandingan Kriteria Model <i>Quantile Regression Neural Network</i> untuk Data Simulasi Setiap Replikasi. ....	87
<b>Gambar 4.27</b>	Perbandingan Data Aktual dan Ramalan Model QRNN pada Skenario 1 (a), Skenario 2 (b), Skenario 3 (c), dan Skenario 4 (d). ....	88
<b>Gambar 4.28</b>	Perbandingan Model ARIMAX, <i>Neural Network</i> , dan <i>Quantile Regression Neural Network</i> untuk Data Simulasi .....	91
<b>Gambar 4.29</b>	Perbandingan Pola Residual Linier dan Nonlinier Berdasarkan Musiman yang Homogen .....	92
<b>Gambar 4.30</b>	Perbandingan Pola Musiman yang Homogen Berdasarkan Residual Linier dan Nonlinier .....	92
<b>Gambar 4.31</b>	Metode Terbaik Tiap Skenario dan Simulasi. ....	93
<b>Gambar 4.32</b>	Perkembangan Jumlah <i>Inflow</i> dan <i>Outflow</i> di Indonesia.....	94
<b>Gambar 4.33</b>	<i>Time Series Plot</i> Data <i>Inflow</i> Secara Agregat dan Tiap Pecahan.....	96
<b>Gambar 4.34</b>	<i>Time Series Plot</i> Data <i>Outflow</i> Secara Agregat dan Tiap Pecahan.....	97
<b>Gambar 4.35</b>	Histogram Data <i>Inflow</i> Tiap Pecahan. ....	99
<b>Gambar 4.36</b>	Histogram Data <i>Outflow</i> Tiap Pecahan. ....	100

<b>Gambar 4.37</b>	Perbandingan Rata-rata <i>Inflow</i> pada Bulan Terjadinya Hari Raya Idul Fitri dan Satu Bulan Setelah Hari Raya Idul Fitri.....	100
<b>Gambar 4.38</b>	Perbandingan Rata-rata <i>Outflow</i> pada Bulan Terjadinya Hari Raya Idul Fitri dan Satu Bulan Sebelum Hari Raya Idul Fitri. ...	101
<b>Gambar 4.39</b>	Identifikasi Heteroskedastisitas Musiman pada <i>Inflow</i> Pecahan Rp 100.000.....	102
<b>Gambar 4.40</b>	Identifikasi Heteroskedastisitas Musiman pada <i>Outflow</i> Pecahan Rp 100.000. ....	103
<b>Gambar 4.41</b>	Plot ACF dan PACF dari Residual <i>Time Series Regression</i> . ....	105
<b>Gambar 4.42</b>	Plot ACF dan PACF dari data residual <i>time series regression</i> yang telah <i>didifferencing</i> . ....	106
<b>Gambar 4.43</b>	Perbandingan Data Aktual dan Ramalan Model ARIMAX untuk Data <i>Inflow</i> dan <i>Outflow</i> . ....	115
<b>Gambar 4.44</b>	PACF Data <i>Inflow</i> Pecahan Rp.1000,00.....	117
<b>Gambar 4.45</b>	Arsitektur Model <i>Neural Network</i> untuk <i>Inflow</i> Rp 1.000,00.....	120
<b>Gambar 4.46</b>	Perbandingan Data Aktual dan Ramalan Model <i>Neural Network</i> untuk Setiap Pecahan. ....	128
<b>Gambar 4.47</b>	Perbandingan <i>Crossing</i> pada Data <i>Training</i> (a) dan <i>Testing</i> (b).....	129
<b>Gambar 4.48</b>	Perbandingan Rata-rata Banyaknya <i>Crossing</i> untuk Setiap Jenis Model QRNN. ....	130
<b>Gambar 4.49</b>	Perbandingan Rata-rata Banyaknya <i>Crossing</i> dan <i>Neuron</i> untuk Setiap Jenis Model QRNN.....	130
<b>Gambar 4.50</b>	Perbandingan Nilai RMSE (a), MdAE (b), dan MdAPE (c) untuk Keenam Model QRNN. ....	132

<b>Gambar 4.51</b>	Perbandingan Data Aktual dan Ramalan Model <i>Quantile Regression Neural Network</i> untuk Setiap Pecahan. ....	139
<b>Gambar 4.52</b>	Perbandingan Data Aktual-Ramalan untuk Metode ARIMAX, NN, dan QRNN. ....	143
<b>Gambar 4.53</b>	Perbandingan Rasio MdAE NN dan QRNN terhadap MdAE ARIMAX .....	144
<b>Gambar 4.54</b>	Perbandingan Model ARIMAX, <i>neural network</i> , dan <i>Quantile Regression Neural Network</i> untuk Data <i>Inflow</i> Dan <i>Outflow</i> . ..	145
<b>Gambar 4.55</b>	Hasil Peramalan <i>Inflow</i> dan <i>Outflow</i> untuk Periode Tahun 2017 (Miliar Rp).....	149

*(Halaman ini sengaja dikosongkan)*



## DAFTAR TABEL

	Halaman
<b>Tabel 2.1</b> Penentuan Operator untuk Model Non-Musiman .....	13
<b>Tabel 2.2</b> Penentuan Operator untuk Model Musiman ....	14
<b>Tabel 2.3</b> Varians Model ARIMA .....	19
<b>Tabel 3.1</b> Variabel Penelitian (dalam miliar rupiah).....	37
<b>Tabel 3.2</b> Struktur Data.....	38
<b>Tabel 3.3</b> Variabel <i>Dummy</i> yang Digunakan .....	39
<b>Tabel 4.1</b> Kejadian Idul Fitri Tahun 2001 hingga 2016...	56
<b>Tabel 4.2</b> Nilai a dan b untuk Simulasi Data Heterogen pada Musiman.....	57
<b>Tabel 4.3</b> Model ARIMA untuk Data Simulasi .....	65
<b>Tabel 4.4</b> Kriteria Evaluasi Model ARIMAX untuk Data Simulasi .....	67
<b>Tabel 4.5</b> Pengujian Linieritas Data Simulasi 1 Replikasi 1 .....	70
<b>Tabel 4.6</b> Pemilihan Model <i>Neural Network</i> Terbaik untuk Skenario 1 Replikasi 1 .....	71
<b>Tabel 4.7</b> <i>Input</i> dan <i>Neuron</i> Optimal Model <i>Neural Network</i> untuk Data Simulasi. ....	75
<b>Tabel 4.8</b> Perbandingan Kriteria RMSE, MAE, MdAE, MdAPE, dan MAPE Model <i>Neural Network</i> untuk Data Simulasi.....	77
<b>Tabel 4.9</b> Pemilihan <i>Neuron</i> Optimal Model <i>Quantile Regression Neural Network</i> untuk Data Simulasi Skenario 1 Replikasi 1 .....	85
<b>Tabel 4.10</b> Perbandingan Kriteria Model <i>Quantile Regression Neural Network</i> untuk Data Simulasi .....	86
<b>Tabel 4.11</b> Perbandingan Model ARIMAX, <i>Neural Network</i> , dan <i>Quantile Regression Neural Network</i> untuk Data Simulasi .....	89
<b>Tabel 4.12</b> Statistika Deskriptif Data <i>Inflow</i> dan <i>Outflow</i> (miliar Rp) .....	98

<b>Tabel 4.13</b>	Estimasi Parameter <i>Time Series Regression</i> untuk Pecahan <i>Outflow</i> Rp 50.000,- .....	104
<b>Tabel 4.14</b>	<i>Ljung-box Test Residual Time Series Regression</i> .....	104
<b>Tabel 4.15</b>	Pengujian stasioneritas residual <i>time series regression</i> .....	105
<b>Tabel 4.16.</b>	Pembentukan model ARIMA.....	106
<b>Tabel 4.17</b>	Pengujian <i>Ljung-Box Residual Model ARIMA</i>	106
<b>Tabel 4.18</b>	Pengujian <i>Lagrange Multiplier Residual Model ARIMA</i> .....	107
<b>Tabel 4.19</b>	Model Terbaik ARIMA untuk Masing-masing Pecahan .....	107
<b>Tabel 4.20</b>	Perbandingan Kriteria Model ARIMAX Data <i>Inflow</i> dan <i>Outflow</i> .....	111
<b>Tabel 4.21</b>	Pengujian Stasioneritas Data <i>Inflow</i> dan <i>Outflow</i> .....	116
<b>Tabel 4.22</b>	Pengujian Stasioneritas Data <i>Inflow</i> dan <i>Outflow</i> yang telah di <i>Differencing</i> .....	117
<b>Tabel 4.23</b>	Kombinasi <i>Input Model Neural Network Data Inflow</i> dan <i>Outflow</i> .....	117
<b>Tabel 4.24</b>	Pengujian Linieritas <i>Input</i> untuk Data <i>Inflow</i> Pecahan Rp.1000,00.....	118
<b>Tabel 4.25</b>	Perbandingan Kriteria dalam Pemilihan <i>Neuron Model Neural Network</i> untuk Data <i>Inflow</i> Pecahan Rp 1.000,00 .....	119
<b>Tabel 4.26</b>	Estimasi Parameter Pembobot <i>Neural Network</i> untuk <i>Inflow</i> Pecahan Rp 1.000,00 .....	121
<b>Tabel 4.27</b>	<i>Input</i> dan <i>Neuron Optimal</i> untuk Setiap Pecahan .....	123
<b>Tabel 4.28</b>	Perbandingan Kriteria Model <i>Neural Network</i> Terbaik untuk Data <i>Inflow</i> dan <i>Outflow</i> .....	124
<b>Tabel 4.29</b>	Perbandingan Kriteria dalam Pemilihan <i>Neuron Model Quantile Regression Neural Network</i> untuk Data <i>Inflow</i> Pecahan Rp 1.000,00.....	133

<b>Tabel 4.30</b>	Estimasi Parameter Model QRNN untuk <i>Inflow</i> Pecahan Rp 1.000,00 .....	133
<b>Tabel 4.31</b>	Perbandingan Kriteria Model <i>Quantile Regression Neural Network</i> untuk Data <i>Inflow</i> dan <i>Outflow</i> .....	135
<b>Tabel 4.32</b>	Perbandingan Model ARIMAX, <i>Neural Network</i> , dan <i>Quantile Regression Neural Network</i> untuk Data <i>Inflow</i> dan <i>Outflow</i> .....	140
<b>Tabel 4.33</b>	Perbandingan Rasio MdAE NN dan QRNN terhadap MdAE ARIMAX.....	144
<b>Tabel 4.34</b>	Karakteristik data <i>inflow</i> dan <i>outflow</i> beserta metode terbaiknya.....	145

*(Halaman ini sengaja dikosongkan)*

## DAFTAR LAMPIRAN

	Halaman
<b>Lampiran 1</b>	Data <i>Inflow</i> dan <i>Outflow</i> di Indonesia .....161
<b>Lampiran 2</b>	PACF Data Simulasi.....162
<b>Lampiran 3</b>	Hasil Pengujian Terasvirta Data Simulasi .....164
<b>Lampiran 4</b>	Perbandingan Kriteria dalam Pemilihan <i>Neuron Model Dekomposisi Quantile</i> <i>Regression Neural Network</i> .....165
<b>Lampiran 5</b>	Identifikasi Heterogen dalam Musiman untuk Setiap Pecahan <i>Inflow</i> .....169
<b>Lampiran 6</b>	<i>Output</i> Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX.....172
<b>Lampiran 7</b>	PACF Data <i>Inflow</i> dan <i>Outflow</i> .....197
<b>Lampiran 8</b>	Hasil Pengujian Terasvirta Data <i>Inflow</i> dan <i>Outflow</i> .....199
<b>Lampiran 9</b>	Hasil Estimasi Parameter Model NN data <i>Inflow</i> dan <i>Outflow</i> .....201
<b>Lampiran 10</b>	Perbandingan Kriteria dalam Pemilihan <i>Neuron</i> dan <i>Input Model Neural Network</i> Tiap Pecahan.....215
<b>Lampiran 11</b>	Hasil Estimasi Parameter Model QRNN Data <i>Inflow</i> dan <i>Outflow</i> .....221
<b>Lampiran 12</b>	Perbandingan Kriteria <i>Testing</i> dalam Pemilihan <i>Neuron Model Quantile</i> <i>Regression Neural Network</i> Tiap Pecahan .....234
<b>Lampiran 13</b>	Hasil Peramalan Data <i>Inflow</i> dan <i>Outflow</i> .....237
<b>Lampiran 14</b>	<i>Syntax</i> Estimasi Parameter Model ARIMAX ..243
<b>Lampiran 15</b>	<i>Syntax</i> Estimasi Parameter Model GARCH ....245
<b>Lampiran 16</b>	<i>Syntax</i> Estimasi Parameter Model <i>Neural</i> <i>Network</i> .....246
<b>Lampiran 17</b>	<i>Syntax</i> Estimasi Parameter Model <i>Quantile</i> <i>Regression Neural Network</i> .....248
<b>Lampiran 18</b>	<i>Syntax</i> Pengujian Asumsi Residual <i>White</i> <i>Noise</i> dan Berdistribusi Normal.....249
<b>Lampiran 19</b>	Surat Keterangan Data Instansi .....250

*(Halaman ini sengaja dikosongkan)*

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

Regresi kuantil merupakan perluasan dari regresi dengan estimasi *Ordinary Least Square* (OLS). Apabila regresi OLS menjelaskan keterkaitan variabel independen ( $X$ ) dengan rata-rata variabel dependen ( $Y$ ), regresi kuantil dapat menjelaskan keterkaitan tersebut pada berbagai kuantil. Regresi kuantil pertama kali diperkenalkan oleh Koenker dan Basset pada tahun 1978 (Chen, 2007). Estimator dalam regresi kuantil diperoleh dengan mengestimasi nilai fungsi kuantil dari suatu distribusi  $Y$  yang merupakan fungsi dari  $X$ . Distribusi data dapat menggambarkan karakteristik dari suatu data, sehingga dapat diperoleh gambaran mengenai pola data yang lebih lengkap. Kelebihan regresi kuantil adalah dapat mengatasi permasalahan sebaran data yang tidak homogen. Selain itu, peramalan dengan regresi kuantil akan memperoleh hasil peramalan berupa peramalan interval. Regresi kuantil pernah digunakan untuk meramalkan *Value at Risk* (VaR) pada beberapa perusahaan di Asia, Eropa, dan Amerika Utara. Apabila dibandingkan dengan model *Exponential Weighted Moving Average* (EWMA) dan estimasi berdasarkan distribusi secara empiris, peramalan dengan regresi kuantil menghasilkan model yang lebih baik (Wong, 2016).

Pada penelitian ini, regresi kuantil diaplikasikan pada data pecahan *inflow* dan *outflow* di Indonesia karena diduga terdapat permasalahan heteroskedastisitas pada data *inflow* dan *outflow*. Berdasarkan penelitian yang dilakukan oleh Guler dan Talasli (2010), peredaran uang di Turki dimodelkan menggunakan *Autoregressive Moving Average – Generalized Autoregressive Conditional Heteroscedasticity* (ARMA-GARCH) dengan memerhatikan pola musiman hari, minggu, bulan, dan hari libur. Model ARIMA dengan variabel *dummy* musiman diestimasi menggunakan *non linier least square*, namun hasil pengujian

ARCH menunjukkan bahwa terdapat efek ARCH pada model yang terbentuk sehingga untuk mengatasi permasalahan heteroskedastisitas, pemodelan dilakukan dengan menggunakan GARCH. Di Indonesia, peramalan *inflow* dan *outflow* juga pernah dilakukan menggunakan metode *time series regression*, ARIMA, dan ARIMAX dan diperoleh hasil bahwa pemodelan menggunakan ARIMAX menghasilkan varians residual yang tidak homogen (Rachmawati, Setiawan, & Suhartono, 2015). Dengan demikian, permasalahan heteroskedastisitas seringkali terjadi pada pemodelan *inflow* dan *outflow* sehingga metode regresi kuantil dapat diaplikasikan pada data *inflow* dan *outflow* di Indonesia.

Peramalan mengenai *inflow* dan *outflow* merupakan hal yang penting untuk mencapai kesesuaian jumlah ketersediaan uang dengan kebutuhan masyarakat karena merupakan indikator yang digunakan dalam menentukan rencana kebutuhan uang dan sebagai salah satu bentuk pengendalian peredaran uang. Pengedaran uang harus dapat dikelola dengan baik agar jumlah uang yang beredar sesuai dengan jumlah uang yang dibutuhkan oleh masyarakat. Jumlah uang beredar yang melebihi kebutuhan masyarakat akan mengakibatkan terjadinya inflasi, sedangkan jumlah uang beredar lebih sedikit dari permintaan akan menyebabkan perekonomian yang melambat. Tujuan dari kebijakan pengedaran uang di Indonesia adalah untuk memenuhi kebutuhan uang di masyarakat dalam jumlah nominal yang cukup, jenis pecahan yang sesuai, tepat waktu, dan dalam kriteria yang layak edar. Untuk mencapai tujuan tersebut, Bank Indonesia melakukan pengelolaan uang yang meliputi pencetakan, pengedaran, pencabutan/penarikan, dan pemusnahan uang (Sigalingging, Setiawan, & Sihaloho, 2004, pp. 5-6).

Kebijakan yang dilakukan oleh Bank Indonesia untuk mewujudkan ketersediaan uang adalah dengan melakukan penyusunan Rencana Kebutuhan Uang (RKU) yang dijadikan dasar dalam pengadaan uang setiap tahunnya. Penetapan RKU didasarkan pada perhitungan proyeksi *inflow* dan *outflow*,



pemusnahan uang rupiah tidak layak edar, dan kecukupan persediaan uang kartal yang dimiliki. Penyusunan RKU merupakan langkah awal yang dilakukan untuk menentukan kebutuhan uang kartal dan dijadikan sebagai dasar perhitungan kebutuhan bahan baku dan kebutuhan cetak uang rupiah (Bank Indonesia, 2012). Hasil RKU ini akan digunakan sebagai dasar dalam menyusun Rencana Distribusi Uang (RDU), yakni penetapan jumlah dan komposisi uang kartal yang akan dikirimkan ke tiap Kantor Bank Indonesia selama satu tahun. Bank Indonesia telah melakukan peramalan *inflow* dan *outflow* secara nasional menggunakan metode *Error Correction Model* yang memperhitungkan variabel ekonomi makro. Peramalan *inflow* dan *outflow* di masing-masing KBI dilakukan dengan berdasarkan tren *historical data series* menggunakan metode dekomposisi (Bank Indonesia, 2010).

Di Indonesia, *inflow* dan *outflow* dapat memiliki pola musiman harian, mingguan, hari libur, dan hari khusus seperti hari raya (Sigalingging, Setiawan, & Sihalohe, 2004, pp. 30-32). Apriliadara, Suhartono, dan Prastyo (2016) telah melakukan peramalan *inflow* dan *outflow* menggunakan metode VARI-X. Dengan metode tersebut peramalan *inflow* dan *outflow* dilakukan secara multivariat dan melibatkan variabel *dummy* berupa hari raya Idul Fitri. Hasil yang diperoleh adalah efek dari hari Idul Fitri berpengaruh pada nilai *inflow* dan *outflow*. Kozinski dan Swist (2015) melakukan peramalan peredaran uang di Polandia menggunakan ARIMA dan SARIMA dengan variabel *dummy* musiman berupa hari dan bulan. Kesimpulan yang diperoleh adalah metode SARIMA dengan variabel *dummy* dapat meramalkan peredaran uang dengan lebih baik. Dengan demikian, pada penelitian ini digunakan variabel *dummy* musiman bulan dan efek variasi kalender yakni terjadinya hari raya Idul Fitri.

Akurasi peramalan merupakan hal yang penting dalam mengevaluasi model peramalan yang telah dibentuk. Akurasi peramalan yang tinggi tentunya dapat meminimumkan biaya dan menyediakan informasi yang lebih baik. Akurasi peramalan dapat

ditingkatkan melalui beberapa cara, salah satunya adalah dengan menggabungkan beberapa metode, atau dikenal dengan metode *hybrid*. Pada umumnya, akurasi peramalan dengan menggunakan kombinasi dua metode akan menghasilkan peramalan yang lebih baik dibandingkan dengan menggunakan satu metode saja (Makridakis & Hibon, 2000). Berdasarkan penelitian yang dilakukan oleh Joseph, Larrain, dan Ottoo (2013), metode *neural network* dapat meramalkan kebutuhan uang dengan baik apabila dibandingkan dengan metode regresi berganda. Penelitian yang dilakukan oleh Hlavacek, Kalous, dan Hakl (2009) juga menunjukkan bahwa terdapat hubungan nonlinier pada pola musiman data peredaran uang, sehingga dalam penelitian ini, metode regresi kuantil dikombinasikan dengan *neural network* atau dikenal dengan metode *hybrid quantile regression neural network*.

Metode *hybrid quantile regression neural network* pernah digunakan oleh Taylor (2000) untuk meramalkan *multi-period returns* dalam berbagai *holding period*. Variabel independen yang digunakan adalah lama *holding period* dan taksiran varians pada periode ke  $t+1$  yang diperoleh melalui pemodelan dengan GARCH. Hasil yang diperoleh adalah metode *quantile regression neural network* memiliki performansi yang lebih baik dibandingkan dengan GARCH menggunakan distribusi empiris, dan cenderung memiliki performansi yang sama dengan metode GARCH menggunakan distribusi *Gaussian* berdasarkan persentase data *testing* yang termuat dalam interval peramalan tertentu. Peramalan menggunakan metode *hybrid quantile regression neural network* juga pernah dilakukan untuk menganalisis data kredit portfolio, hasil yang diperoleh adalah metode *quantile regression neural network* lebih *robust* terhadap *outlier* dan memiliki performa yang lebih baik apabila dibandingkan dengan metode nonparametrik lainnya yakni *local linear regression* dan *regression spline* (Feng, Li, Sudjianto, & Zhang, 2010).

Pada penelitian ini dilakukan peramalan interval untuk *inflow* dan *outflow* di Indonesia dengan menggunakan *quantile regression neural network*. Data peredaran uang telah banyak diramalkan menggunakan ARIMA (Nasiru, Luguterah, & Anzagra, 2013; Ikoku, 2014; Kozinski & Swist, 2015). Metode ARIMA merupakan metode peramalan univariat yang banyak digunakan dalam berbagai bidang (Zhang, 2003). Salah satu pengembangan metode ARIMA yang dapat menangkap pola-pola khusus seperti variasi kalender adalah metode ARIMAX. Dengan demikian, dilakukan perbandingan hasil peramalan *inflow* dan *outflow* dengan metode ARIMAX. Kriteria yang digunakan dalam membandingkan kebaikan model ARIMAX dan *quantile regression neural network* adalah kriteria RMSE, MAE, MdAE, MdAPE, dan MAPE, serta kebaikan peramalan interval yang terbentuk berdasarkan persentase pengamatan yang berada dibawah kuantil tertentu.

## 1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, permasalahan yang dibahas dalam penelitian ini adalah bagaimana membentuk model peramalan *inflow* dan *outflow* tiap pecahan di Indonesia yang akurat dan dapat menangkap pola variasi kalender serta heteroskedastisitas. Permasalahan secara spesifik dapat dirumuskan sebagai berikut.

1. Bagaimana hasil perbandingan performa metode ARIMA, *neural network* dan *quantile regression neural network* dalam mengatasi permasalahan heteroskedastisitas dan nonlinieritas berdasarkan hasil studi simulasi?
2. Bagaimana karakteristik dan pola data *inflow* dan *outflow* uang kartal di Indonesia?
3. Bagaimana model peramalan titik dan interval pada data *inflow* dan *outflow* di Indonesia menggunakan metode ARIMAX?
4. Bagaimana model peramalan titik pada data *inflow* dan *outflow* di Indonesia menggunakan metode *neural network*?

5. Bagaimana model peramalan titik dan interval pada data *inflow* dan *outflow* di Indonesia menggunakan metode *quantile regression neural network*?
6. Bagaimana hasil perbandingan akurasi peramalan data *inflow* dan *outflow* di Indonesia menggunakan ARIMAX, *neural network*, dan *quantile regression neural network*?
7. Bagaimana hasil peramalan titik dan interval pada data *inflow* dan *outflow* di Indonesia pada tahun 2017?

### 1.3 Tujuan

Berdasarkan rumusan masalah di atas, tujuan penelitian ini secara umum adalah untuk memperoleh model peramalan *inflow* dan *outflow* tiap pecahan di Indonesia yang akurat dan dapat menangkap pola variasi kalender serta heteroskedastisitas. Secara spesifik, tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut.

1. Membandingkan metode ARIMA, *neural network* dan *quantile regression neural network* dalam mengatasi permasalahan heteroskedastisitas dan nonlinieritas pada data studi simulasi.
2. Mendeskripsikan karakteristik dan pola data *inflow* dan *outflow* uang kartal di Indonesia.
3. Memodelkan data *inflow* dan *outflow* di Indonesia menggunakan metode ARIMAX.
4. Memodelkan data *inflow* dan *outflow* di Indonesia menggunakan metode *neural network*.
5. Memodelkan data *inflow* dan *outflow* di Indonesia menggunakan metode *quantile regression neural network*.
6. Membandingkan akurasi peramalan data *inflow* dan *outflow* di Indonesia menggunakan ARIMAX, *neural network*, dan *quantile regression neural network*.
7. Meramalkan data *inflow* dan *outflow* di Indonesia pada tahun 2017.

#### 1.4 Manfaat

Penelitian ini diharapkan dapat memberikan beberapa manfaat bagi berbagai pihak, diantaranya sebagai berikut.

1. Memberikan tambahan informasi yang dapat digunakan sebagai bahan pertimbangan Bank Indonesia dalam melakukan pencetakan uang pada tahun 2017 sehingga tercapai kesesuaian jumlah uang beredar dengan kebutuhan masyarakat.
2. Memberikan wawasan keilmuan statistika terkait dengan penerapan metode ARIMAX, *neural network*, dan *quantile regression neural network*.

#### 1.5 Batasan Masalah

Batasan masalah dalam penelitian ini adalah data yang digunakan merupakan data pecahan *inflow* dan *outflow* pada tahun 2003 hingga 2016 sebanyak tujuh pecahan. Pada analisis menggunakan *quantile regression neural network*, *hidden layer* yang digunakan adalah *single hidden layer*. Variabel *dummy* yang digunakan hanya variabel *dummy* untuk musiman bulan, tren, dan variasi kalender yakni efek hari raya Idul Fitri.

*(Halaman ini sengaja dikosongkan)*

## **BAB II**

### **TINJAUAN PUSTAKA**

Tinjauan pustaka pada penelitian ini membahas mengenai analisis deret waktu, model *time series regression* dengan variasi kalender, ACF dan PACF, ARIMA, ARIMAX, GARCH, *quantile regression*, *neural network*, *quantile regression neural network*, Evaluasi model, *inflow* dan *outflow* uang kartal, serta penyusunan kebutuhan uang di Bank Indonesia.

#### **2.1 Analisis Deret Waktu**

Data dapat diperoleh dari pengamatan yang disusun secara berurutan dari waktu ke waktu dengan interval yang sama. Data yang disusun secara berurutan dari waktu ke waktu seringkali memiliki tenggang antara kesadaran akan peristiwa tersebut dan terjadinya peristiwa tersebut. Adanya waktu tenggang (*lead time*) ini merupakan alasan utama diperlukan perencanaan dan peramalan. Apabila waktu tenggang adalah nol atau sangat kecil, maka tidak diperlukan suatu perencanaan. Namun, apabila waktu tenggang suatu peristiwa cenderung lama, dan hasil suatu peristiwa bergantung pada faktor tertentu, maka perencanaan memegang peranan penting. Dalam kondisi tersebut, peramalan diperlukan untuk menentukan kapan suatu peristiwa akan terjadi atau kebutuhan yang muncul pada waktu tertentu, sehingga dapat memberikan pertimbangan dalam pengambilan keputusan yang tepat (Makridakis, Wheelwright, & Hyndman, 1998, pp. 2-3). Dengan demikian, tujuan dari analisis deret waktu adalah untuk memahami atau memodelkan suatu proses stokastik dari suatu deret yang diamati dan untuk memprediksi atau meramalkan nilai masa depan berdasarkan kejadian sebelumnya maupun faktor terkait lainnya.

#### **2.2 Model Regresi *Time Series* dengan Variasi Kalender**

Efek variasi kalender telah banyak digunakan dalam analisis *time series*. Efek variasi kalender pertama kali digunakan oleh Liu pada tahun 1980 dan Cleveland dan Devlin pada tahun

yang sama. Model regresi *time series* dengan variasi kalender merupakan model *time series* yang digunakan untuk melakukan peramalan berdasarkan pola musiman dengan periode yang bervariasi. Pola musiman yang diamati pada penelitian ini adalah pola kejadian Idul Fitri yang terjadi pada bulan tertentu. Data dengan variasi kalender dapat dimodelkan menggunakan model regresi (Lee, Suhartono, & Hamzah, 2010; Suhartono, Lee, & Prastyo, 2015). Model regresi linier dengan variasi kalender dapat ditunjukkan oleh

$$Y_t = \beta_0 + \beta_1 V_{1,t} + \beta_2 V_{2,t} + \dots + \beta_h V_{h,t} + a_t, \quad (2.1)$$

dengan  $V_{h,t}$  merupakan variabel *dummy* untuk variasi kalender ke  $h$ . Banyaknya efek variasi kalender yang digunakan dapat diidentifikasi berdasarkan plot *time series* dari data yang dianalisis. Pada penelitian ini, model variasi kalender untuk data *inflow* dan *outflow* dilakukan dengan menambahkan variabel *dummy* sebagai variasi kalender yang ditunjukkan oleh

$$Y_t = \alpha_1 t + \beta_1 M_{1,t} + \beta_2 M_{2,t} + \dots + \beta_{12} M_{12,t} + \gamma_1 V_{1,t} + \dots + \gamma_4 V_{4,t} + \gamma_5 V_{1,t+1} + \dots + \gamma_8 V_{4,t+1} + a_t, \quad (2.2)$$

$$Y_t = \alpha_1 t + \beta_1 M_{1,t} + \beta_2 M_{2,t} + \dots + \beta_{12} M_{12,t} + \gamma_1 V_{1,t} + \dots + \gamma_4 V_{4,t} + \gamma_5 V_{1,t-1} + \dots + \gamma_8 V_{4,t-1} + a_t, \quad (2.3)$$

dengan  $t$  merupakan variabel *dummy* untuk tren,  $M_{1,t}, \dots, M_{12,t}$  merupakan variabel *dummy* untuk bulan, dan  $V_{1,t}, \dots, V_{8,t}$  variabel *dummy* untuk Idul Fitri. Model variasi kalender untuk data *inflow* dapat ditunjukkan pada persamaan (2.2), sedangkan persamaan (2.3) merupakan model variasi kalender untuk data *outflow*.

### 2.3 ACF dan PACF

*Autocorrelation Function* (ACF) merupakan korelasi antara  $Y_t$  dan  $Y_{t+k}$  dari proses yang sama pada *lag* waktu yang berbeda (Wei, 2006, pp. 10-11). Perhitungan ACF untuk sampel  $Y_1, Y_2, \dots, Y_n$  dapat diperoleh melalui



$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2}, \quad k=0,1,2,\dots \quad (2.4)$$

dengan  $K < n$  dan  $\bar{Y} = \sum_{t=1}^n Y_t / n$ , merupakan rata-rata dari sampel (Wei, 2006, pp. 20-22).

Dalam analisis *time series*, perlu dilakukan pula perhitungan korelasi antara  $Y_t$  dan  $Y_{t+k}$  namun korelasi antara  $Y_t$  dan  $Y_{t+k}$  dengan  $Y_{t+1}, \dots, Y_{t+k-1}$  telah dihilangkan. Korelasi bersyarat  $\text{Corr}(Y_t, Y_{t+k} | Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1})$  inilah yang merupakan *Partial Autocorrelation* (PACF) dalam analisis *time series* (Wei, 2006, pp. 11-15). Perhitungan PACF untuk sampel dapat diperoleh melalui (Wei, 2006, pp. 22-23) :

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j}, \quad (2.5)$$

dan

$$\hat{\phi}_{k+1,j} = \hat{\phi}_{k,j} - \hat{\phi}_{k+1,k+1} \hat{\phi}_{k,k+1-j}, \quad j=1,2,\dots,k. \quad (2.6)$$

## 2.4 Autoregressive Integrated Moving Average (ARIMA)

Model ARMA merupakan model gabungan dari proses *Autoregressive* dan *Moving Average*. Proses AR merupakan proses yang menjelaskan kondisi  $Y_t$  yang dipengaruhi oleh kondisi sebelumnya ( $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$ ) dan memiliki  $a_t$  yang bersifat *white noise*. Proses MA merupakan proses yang menunjukkan bahwa nilai estimasi  $Y_t$  dipengaruhi oleh *error* pada waktu ke- $t$  dan *error* sebelumnya ( $a_{t-1}, a_{t-2}, \dots, a_{t-q}$ ). Model ARMA sangat bermanfaat dalam mendeskripsikan data yang stasioner. Data *time series* yang tidak stasioner dalam *mean* dapat *didifferencing* pada orde tertentu sehingga terbentuk data yang stasioner. Persamaan umum

dari model ARIMA  $(p,d,q)$  ditunjukkan oleh (Wei, 2006, pp. 71-72)

$$\phi_p(B)(1-B)^d Y_t = \theta_0 + \theta_q(B) a_t, \quad (2.7)$$

dengan

$$\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p), p \text{ merupakan orde untuk AR,}$$

$$\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q), q \text{ merupakan orde untuk MA,}$$

$$(1-B)^d = \text{operator differencing untuk orde } d,$$

$$a_t = \text{error pada waktu ke-} t.$$

Parameter  $\theta_0$  berperan penting ketika  $d=0$  dan  $d>0$ . Ketika  $d=0$  maka proses telah stasioner, koefisien  $\theta_0$  menunjukkan rata-rata proses  $\theta_0 = \mu(1 - \phi_1 - \dots - \phi_p)$ . Namun ketika  $d \geq 1$ ,  $\theta_0$  menunjukkan komponen untuk *trend* dan dapat dihilangkan apabila tidak diperlukan.

Dalam pembentukan model ARIMA, terdapat beberapa tahapan yang dilakukan, yakni identifikasi, estimasi parameter, dan cek diagnosa.

#### 2.4.1 Identifikasi

Pada tahap identifikasi langkah yang dilakukan adalah identifikasi pola *time series*, menguji kestasioneran data dan identifikasi plot ACF serta PACF (Wei, 2006, pp. 108-109). Data yang digunakan dalam pemodelan dengan ARIMA harus memenuhi asumsi stasioner dalam *mean* dan varians. Pengujian stasioneritas dalam *mean* dapat dilakukan menggunakan uji Dickey Fuller. Apabila data belum memenuhi asumsi stasioneritas dalam *mean* maka dilakukan *differencing* menggunakan

$$W_t = (1-B)^d Y_t. \quad (2.8)$$

Apabila data belum memenuhi asumsi stasioneritas dalam varian maka dilakukan transformasi menggunakan transformasi Box-Cox. Persamaan yang digunakan dalam transformasi Box-Cox adalah

$$Y_t^{(\lambda)} = \begin{cases} \frac{Y_t^\lambda - 1}{\lambda}, \lambda \neq 0 \\ \log(Y_t), \lambda = 0, \end{cases} \quad (2.9)$$

dengan  $\lambda$  merupakan parameter pada transformasi Box-Cox (Box & Cox, 1964).

Setelah data memenuhi asumsi stasioneritas dalam *mean* dan *varians*, tahapan selanjutnya adalah menentukan orde ARMA berdasarkan karakteristik plot ACF dan PACF yang ditunjukkan pada Tabel 2.1 dan Tabel 2.2 (Bowerman & O'Connell, 1993, pp. 572-574).

**Tabel 2.1** Penentuan Operator untuk Model Non-Musiman

No	Pola ACF dan PACF	Model
1	Plot PACF signifikan pada lag 1,2,...,p dan <i>cuts off</i> setelah lag p, sedangkan plot ACF berpola <i>dies down</i> .	$\phi_p(B)$ .
2	Plot ACF signifikan pada lag 1,2,...,q dan <i>cuts off</i> setelah lag q, sedangkan plot PACF berpola <i>dies down</i> .	$\theta_q(B)$ .
3	Plot PACF signifikan pada lag 1,2,...,p dan <i>cuts off</i> setelah lag p, sedangkan plot ACF signifikan pada lag 1,2,...,q dan <i>cuts off</i> setelah lag q.	$\phi_p(B)$ atau $\theta_q(B)$ . Apabila plot ACF memiliki pola <i>cuts off</i> lebih tajam maka operator model ARIMA yang digunakan adalah $\theta_q(B)$ , apabila plot PACF memiliki pola <i>cuts off</i> lebih tajam, maka operator yang digunakan adalah $\phi_p(B)$ . Apabila pola <i>cuts off</i> keduanya sama, maka dapat digunakan operator $\phi_p(B)$ atau $\theta_q(B)$ sebagai model dugaan sementara. Kemudian dilakukan estimasi, cek diagnosa dan peramalan untuk menentukan model terbaiknya.

**Tabel 2.1** Penentuan Operator untuk Model Non-Musiman (*Lanjutan*)

No	Pola ACF dan PACF	Model
4	Plot ACF memiliki autokorelasi yang kecil (tidak signifikan) pada semua <i>lag</i> dan plot PACF memiliki autokorelasi parsial yang kecil (tidak signifikan) pada semua <i>lag</i> .	Tidak memiliki operator model non-musiman.
5	Plot ACF dan PACF memiliki pola <i>dies down</i> .	$\phi_p(B)$ dan $\theta_q(B)$ .

Identifikasi orde ACF dan PACF untuk pola musiman dengan periode musiman  $S$  dapat ditunjukkan oleh Tabel 2.2.

**Tabel 2.2** Penentuan Operator untuk Model Musiman

No	Pola ACF dan PACF	Model
1.	Plot PACF signifikan pada <i>lag</i> $L, 2L, \dots, PL$ dan <i>cuts off</i> setelah <i>lag</i> $PS$ , sedangkan plot ACF berpola <i>dies down</i> .	$\phi_p(B^L)$ .
2.	Plot ACF signifikan pada <i>lag</i> $L, 2L, \dots, QL$ dan <i>cuts off</i> setelah <i>lag</i> $QL$ , sedangkan plot PACF berpola <i>dies down</i> .	$\theta_q(B^L)$ .
3.	Plot PACF signifikan pada <i>lag</i> $L, 2L, \dots, PL$ dan <i>cuts off</i> setelah <i>lag</i> $PL$ , sedangkan plot ACF signifikan pada <i>lag</i> $L, 2L, \dots, QL$ dan <i>cuts off</i> setelah <i>lag</i> $QL$ .	$\phi_p(B^L)$ atau $\theta_q(B^L)$ . Apabila plot ACF memiliki pola <i>cuts off</i> lebih tajam maka operator yang digunakan adalah $\theta_q(B^L)$ , apabila plot PACF memiliki pola <i>cuts off</i> lebih tajam, maka operator yang digunakan adalah $\phi_p(B^L)$ . Apabila pola <i>cuts off</i> keduanya sama, maka dapat digunakan operator $\phi_p(B^L)$ atau $\theta_q(B^L)$ sebagai model dugaan sementara. Kemudian dilakukan estimasi, cek diagnosa dan peramalan untuk menentukan model terbaiknya.

**Tabel 2.2** Penentuan Operator untuk Model Musiman (*Lanjutan*)

No	Pola ACF dan PACF	Model
4.	Plot ACF memiliki autokorelasi yang kecil (tidak signifikan) pada semua <i>lag</i> musiman dan plot PACF memiliki autokorelasi parsial yang kecil (tidak signifikan) pada semua <i>lag</i> musiman.	Tidak memiliki operator musiman.
5.	Plot ACF dan PACF memiliki pola <i>dies down</i> pada <i>lag</i> musiman.	$\phi_p(B^L)$ dan $\theta_q(B^L)$ .

### 2.4.2 Estimasi Parameter dan Uji Signifikansi

Tahap estimasi parameter bertujuan untuk memperoleh nilai dari setiap parameter dalam model ARIMA. Estimasi parameter dari model dugaan dapat dilakukan menggunakan metode *Maximum Likelihood Estimation* (MLE). Pada metode MLE seluruh informasi dari data akan digunakan, sehingga tidak hanya terbatas pada momen pertama atau kedua. Estimasi parameter menggunakan MLE pada dasarnya terdiri dari dua tahapan yakni menentukan fungsi *likelihood* dan menentukan nilai taksiran yang memaksimumkan fungsi *likelihood* yang telah diperoleh (Hamilton, 1994, p. 117). Misal model AR( $p$ ) :

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + a_t. \quad (2.10)$$

dengan  $a_t \sim \text{i.i.d. } N(0, \sigma^2)$ . Untuk pengamatan  $Y_1, Y_2, \dots, Y_n$ , fungsi *likelihood*  $L$  merupakan *joint probability density* dari data yang diamati. Sehingga untuk model AR( $p$ ),  $L$  merupakan fungsi dari  $\phi$  dan  $\sigma^2$  dengan syarat  $Y_1, Y_2, \dots, Y_n$ . Dengan demikian, fungsi *likelihood*  $L$  dapat dituliskan sebagai:

$$\begin{aligned} L(a_1, a_2, \dots, a_n) &= \prod_{t=1}^n \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}(a_t)^2} \\ &= \left( \frac{1}{\sqrt{2\pi}\sigma} \right)^n e^{-\frac{1}{2}(a_1^2 + a_2^2 + \dots + a_n^2)}. \end{aligned} \quad (2.11)$$

Untuk mempermudah perhitungan dalam memaksimumkan fungsi *likelihood* pada persamaan (2.11), maka akan digunakan  $\ln$  untuk fungsi *likelihood* tersebut, sehingga diperoleh

$$\begin{aligned}\ln L(a_1, a_2, \dots, a_n) &= \ln \left( \frac{1}{\sqrt{2\pi}\sigma} \right)^n + \left( -\frac{1}{2\sigma^2} (a_1^2 + a_2^2 + \dots + a_n^2) \right) \\ &= \ln \left( \frac{1}{\sqrt{2\pi}\sigma} \right)^n + \left( -\frac{1}{2\sigma^2} \sum_{t=1}^n a_t^2 \right).\end{aligned}\quad (2.12)$$

Memaksimumkan fungsi pada persamaan (2.12) untuk parameter  $\phi_1$  akan sama dengan meminimumkan  $\frac{1}{2\sigma^2} \left( \sum_{t=1}^n a_t^2 \right)$ . Misal :

$$Q = \frac{1}{2\sigma^2} \left( \sum_{t=1}^n a_t^2 \right), \quad (2.13)$$

maka untuk meminimumkan  $Q$  dapat diperoleh melalui (Hamilton, 1994, pp. 118-126):

$$\frac{dQ}{d\phi} = 0. \quad (2.14)$$

Berdasarkan persamaan (2.10), dapat diketahui bahwa untuk model AR(1) nilai  $a_t$  akan ekivalen dengan  $Y_t - \phi_1 Y_{t-1}$ . Sehingga dapat diperoleh:

$$\begin{aligned}\frac{d \left[ \sum_{t=1}^n (Y_t - \phi_1 Y_{t-1})^2 \right]}{d\phi_1} &= 0 \\ 2 \sum_{t=1}^n (Y_t - \phi_1 Y_{t-1})(-Y_{t-1}) &= 0 \\ \sum_{t=1}^n (-Y_t Y_{t-1} + \phi_1 Y_{t-1}^2) &= 0 \\ -\sum_{t=1}^n Y_t Y_{t-1} + \sum_{t=1}^n \phi_1 Y_{t-1}^2 &= 0.\end{aligned}\quad (2.15)$$

Berdasarkan persamaan (2.15), nilai  $\phi_1$  dapat dituliskan sebagai:

$$\hat{\phi}_1 = \frac{\sum_{t=1}^n Y_t Y_{t-1}}{\sum_{t=1}^n \phi_1^2 Y_{t-1}^2}. \quad (2.16)$$

Dengan memisalkan bahwa  $a_1=0$ , maka parameter  $\phi_1$  dapat diketahui melalui:

$$\hat{\phi}_1 = \frac{\sum_{t=2}^n Y_t Y_{t-1}}{\sum_{t=2}^n \phi_1^2 Y_{t-1}^2}. \quad (2.17)$$

Proses estimasi hingga diperoleh persamaan (2.17) juga dapat disebut sebagai *conditional likelihood estimation*. Untuk model AR( $p$ ), nilai  $a_t = Y_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2} - \dots - \phi_p Y_{t-p}$ . Sehingga untuk meminimumkan persamaan (2.13), estimasi parameter untuk  $\phi_1$  dapat ditunjukkan dengan

$$\begin{aligned} & \frac{\partial \left[ \sum_{t=p+1}^n (Y_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2} - \dots - \phi_p Y_{t-p})^2 \right]}{\partial \phi_1} = 0 \\ & 2 \sum_{t=p+1}^n (Y_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2} - \dots - \phi_p Y_{t-p}) (-Y_{t-1}) = 0 \\ & \sum_{t=p+1}^n (Y_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2} - \dots - \phi_p Y_{t-p}) (Y_{t-1}) = 0. \end{aligned} \quad (2.18)$$

Persamaan (2.18) juga dapat dituliskan menjadi:

$$\begin{aligned} \sum_{t=p+1}^n (Y_t Y_{t-1}) &= \left( \sum_{t=p+1}^n (Y_{t-1})^2 \right) \phi_1 + \left( \sum_{t=p+1}^n (Y_{t-1} Y_{t-2}) \phi_2 \right) + \dots + \\ & \left( \sum_{t=p+1}^n (Y_{t-1} Y_{t-p}) \right) \phi_p. \end{aligned} \quad (2.19)$$

Hasil dari perhitungan  $\sum_{t=p+1}^n (Y_t Y_{t-1})$  akan mendekati nilai *numerator* dari koefisien autokorelasi  $r_1$  dengan  $\bar{Y}=0$ . Hal ini juga berlaku

untuk  $\sum_{t=p+1}^n (Y_{t-1}Y_{t-2})$  hingga  $\sum_{t=p+1}^n (Y_{t-1}Y_{t-p})$ . Sehingga apabila kedua sisi dibagi dengan  $\sum_{t=p+1}^n (Y_t)^2$ , akan diperoleh :

$$r_1 = \phi_1 + r_1\phi_2 + r_2\phi_3 + \dots + r_{p-1}\phi_p. \quad (2.20)$$

Estimasi parameter untuk  $\phi_2, \phi_3, \dots, \phi_p$  juga dapat dilakukan dengan cara yang sama. Sehingga akan diperoleh

$$\begin{aligned} r_1 &= \phi_1 + r_1\phi_2 + r_2\phi_3 + \dots + r_{p-1}\phi_p \\ r_2 &= r_1\phi_1 + \phi_2 + r_1\phi_3 + \dots + r_{p-2}\phi_p \\ &\vdots \\ r_p &= r_{p-1}\phi_1 + r_{p-2}\phi_2 + r_{p-3}\phi_3 + \dots + \phi_p. \end{aligned} \quad (2.21)$$

Persamaan (2.21) disebut juga persamaan Yule-Walker untuk model AR( $p$ ) (Cryer & Chan, 2008). Berdasarkan persamaan (2.21), maka nilai  $\phi_1, \phi_2, \phi_3, \dots, \phi_p$  dapat ditentukan melalui

$$\begin{bmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_p \end{bmatrix} = \begin{bmatrix} 1 & r_1 & r_2 & \cdots & r_{p-1} \\ r_1 & 1 & r_1 & \cdots & r_{p-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ r_{p-1} & r_{p-2} & r_{p-3} & \cdots & 1 \end{bmatrix}^{-1} \begin{bmatrix} r_1 \\ r_2 \\ \vdots \\ r_p \end{bmatrix}. \quad (2.22)$$

Model MA( $q$ ) dapat dituliskan sebagai

$$Y_t = -\theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} + a_t. \quad (2.23)$$

Untuk model MA(1), ditunjukkan oleh:

$$Y_t = -\theta_1 a_{t-1} + a_t. \quad (2.24)$$

Bentuk *invertible* persamaan model MA(1) dapat dituliskan dengan:

$$Y_t = -\theta_1 Y_{t-1} + \theta_1^2 Y_{t-2} - \theta_1^3 Y_{t-3} + \dots + (-\theta_1)^k Y_{t-k} + a_t. \quad (2.25)$$

Fungsi *likelihood* untuk model MA(1) juga dapat diperoleh menggunakan persamaan (2.12). Berdasarkan persamaan (2.25), nilai  $a_t$  sama dengan  $Y_t + \theta_1 Y_{t-1} - \theta_1^2 Y_{t-2} + \theta_1^3 Y_{t-3} + \dots + (-\theta_1)^{k+1} Y_{t-k}$ . Sehingga meminimumkan persamaan (2.13) untuk  $\theta_1$  akan ekuivalen dengan:



$$\frac{\partial \left[ \sum_{t=1}^n \left( Y_t + \theta_1 Y_{t-1} - \theta_1^2 Y_{t-2} + \theta_1^3 Y_{t-3} + \dots + (-\theta_1)^{k+1} Y_{t-k} \right)^2 \right]}{\partial \theta_1} = 0. \quad (2.26)$$

Berdasarkan persamaan (2.26), dapat diketahui bahwa fungsi *ln likelihood* model MA(1) merupakan fungsi nonlinier yang kompleks untuk parameter  $\theta_1$ . Hal ini mengakibatkan proses estimasi secara analitis tidak dapat dilakukan. Dengan demikian estimasi MLE untuk model MA(1) dapat dilakukan melalui optimasi secara numerik (Hamilton, 1994, pp. 127-131). Sedangkan untuk model MA( $q$ ) seperti pada persamaan (2.23), meminimumkan  $\theta_1, \theta_2, \dots, \theta_q$  dilakukan menggunakan pendekatan numerik secara multivariat (Hamilton, 1994, pp. 133-142).

Untuk ukuran sampel  $n$  yang relatif besar, distribusi dari penaksir parameter MLE mengikuti distribusi  $N(\theta_0, \mathbf{n}^{-1}, \boldsymbol{\Sigma}^{-1})$ , dengan  $\theta_0$  merupakan vektor yang berisi parameter dan matriks  $\boldsymbol{\Sigma}$  merupakan *information matrix*. Secara umum, perhitungan *standard error* untuk estimator MLE dilakukan melalui proses diferensial kedua dari (Hamilton, 1994, p. 143)

$$\boldsymbol{\Sigma}_{2D} = -n^{-1} \frac{\partial^2 L(\theta)}{\partial \theta \partial \theta} \bigg|_{\theta=\theta_0}. \quad (2.27)$$

Secara khusus, varians untuk beberapa model ARIMA dapat ditunjukkan oleh Tabel 2.3 (Cryer & Chan, 2008, p. 161).

**Tabel 2.3** Varians Model ARIMA

Model ARIMA	Varians
AR(1)	$\text{var}(\hat{\phi}) \approx \frac{1-\phi^2}{n}$
AR(2)	$\text{var}(\hat{\phi}_1) \approx \text{var}(\hat{\phi}_2) \approx \frac{1-\phi_2^2}{n}$
MA(1)	$\text{var}(\hat{\theta}) \approx \frac{1-\theta^2}{n}$

**Tabel 2.3** Varians Model ARIMA (*Lanjutan*)

Model ARIMA	Varians
MA(2)	$\text{var}(\hat{\theta}_1) \approx \text{var}(\hat{\theta}_2) \approx \frac{1 - \theta_2^2}{n}$
ARMA(1,1)	$\text{var}(\hat{\phi}) \approx \left[ \frac{1 - \phi^2}{n} \right] \left[ \frac{1 - \phi\theta}{\phi - \theta} \right]^2$ $\text{var}(\hat{\theta}) \approx \left[ \frac{1 - \theta^2}{n} \right] \left[ \frac{1 - \phi\theta}{\phi - \theta} \right]^2$

Setelah diperoleh nilai estimasi dan *standard error* dari parameter-parameter model ARIMA, tahapan selanjutnya adalah melakukan pengujian signifikansi parameter. Hipotesis yang digunakan untuk melakukan pengujian signifikansi parameter model AR adalah

$$H_0: \phi_j = 0,$$

$$H_1: \phi_j \neq 0, \text{ dengan } j=1,2,\dots,p.$$

Statistik uji yang digunakan adalah:

$$t_{hitung} = \frac{\hat{\phi}_j}{SE(\hat{\phi}_j)}. \quad (2.28)$$

dengan  $SE(\hat{\phi}_j)$  merupakan *standard error* dari parameter model AR.  $H_0$  ditolak apabila nilai statistik uji  $|t_{hitung}| > t_{\alpha/2, (n-n_p)}$ , dengan  $n$  merupakan banyaknya pengamatan dan  $n_p$  merupakan banyaknya parameter yang diestimasi. Hipotesis yang digunakan untuk melakukan pengujian signifikansi parameter model MA adalah

$$H_0: \theta_j = 0,$$

$$H_1: \theta_j \neq 0, \text{ dengan } j=1,2,\dots,q.$$

Statistik uji yang digunakan adalah:

$$t_{hitung} = \frac{\hat{\theta}_j}{SE(\hat{\theta}_j)}. \quad (2.29)$$

dengan  $SE(\hat{\theta}_j)$  merupakan *standard error* dari parameter model MA.  $H_0$  ditolak apabila nilai statistik uji  $|t_{hitung}| > t_{\alpha/2, (n-n_q)}$ , dengan  $n$  merupakan banyaknya pengamatan dan  $n_q$  merupakan banyaknya parameter yang diestimasi.

### 2.4.3 Cek Diagnosa

Model ARIMA harus memenuhi asumsi *white noise* (residual bersifat identik dan independen) serta berdistribusi normal. Untuk melakukan pengujian asumsi independen, dapat dilakukan dengan menggunakan Ljung-Box *test*. Pengujian ini dilakukan menggunakan autokorelasi dari residual sampel. Hipotesis yang digunakan untuk uji Ljung-Box adalah

$H_0$  :  $\rho_1 = \rho_2 = \dots = \rho_K = 0$  (residual independen),

$H_1$  : minimal ada satu nilai  $\rho_k \neq 0$  dengan  $k = 1, 2, \dots, K$  (residual tidak independen).

Perhitungan statistik uji  $Q$  dapat dilakukan menggunakan (Wei, 2006, pp. 152-153)

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k}, \quad (2.30)$$

$H_0$  ditolak apabila nilai  $Q > \chi^2_{\alpha, K-p-q}$ , dengan  $\hat{\rho}_k$  merupakan autokorelasi dari residual, nilai  $p$  adalah banyaknya parameter AR pada model,  $q$  adalah banyaknya parameter MA pada model,  $n$  adalah banyaknya pengamatan, dan  $\alpha$  adalah taraf signifikansi yang digunakan.

Pengujian residual bersifat identik (homogen) dapat dilakukan menggunakan pengujian efek ARCH yang dikenalkan oleh Engle (Wei, 2006, pp. 369-370). Model AR(s) untuk  $\hat{n}_{t-s}^2$  dapat ditunjukkan oleh

$$\hat{n}_t^2 = \theta_0 + \theta_1 \hat{n}_{t-1}^2 + \dots + \theta_s \hat{n}_{t-s}^2 + a_t, \quad (2.31)$$

untuk  $t = s+1, s+2, \dots, n$ . Dengan hipotesis yang digunakan adalah:

$H_0$ :  $\theta_1 = \dots = \theta_s = 0$

$H_1$ : minimal terdapat terdapat  $\theta_j$  dengan  $\theta_j \neq 0$ , untuk  $j=1, 2, \dots, s$ .

Apabila  $H_0$  gagal ditolak maka estimasi untuk  $\theta_j$  mendekati nol dan mengakibatkan koefisien determinasi ( $R^2$ ) bernilai kecil. Statistik uji yang digunakan ditunjukkan oleh

$$LM = (n - s)R^2. \quad (2.32)$$

Dengan  $R^2 = 1 - \frac{SSE}{SST}$  dari model regresi pada persamaan (2.31).

Apabila nilai LM lebih besar daripada nilai  $\chi^2(s)$ , maka terdapat efek ARCH pada residual, dengan kata lain, residual tidak memenuhi asumsi identik.

Pengujian distribusi normal untuk residual dapat dilakukan menggunakan uji Kolmogorov-Smirnov. Berikut adalah hipotesis yang digunakan (Daniel, 1989, pp. 343-345):

$H_0: F(a_i) = F_0(a_i)$  (Residual mengikuti distribusi normal),

$H_1: F(a_i) \neq F_0(a_i)$  (Residual tidak mengikuti distribusi normal).

Statistik uji yang digunakan adalah

$$D = \text{Sup} |F(a_i) - F_0(a_i)|, \quad (2.33)$$

dengan:

$F(a_i)$  = fungsi distribusi frekuensi kumulatif residual,

$F_0(a_i)$  = fungsi distribusi frekuensi kumulatif distribusi normal,

$\text{Sup}$  = nilai maksimum dari  $F(a_i) - F_0(a_i)$ .

$H_0$  ditolak apabila nilai  $D$  lebih besar dari nilai tabel Kolmogorov-Smirnov yaitu  $d_{n,\alpha}$  dengan  $n$  adalah banyaknya pengamatan dan  $\alpha$  adalah taraf signifikansi yang digunakan.

## 2.5 *Autoregressive Integrated Moving Average with Exogeneous Variable (ARIMAX)*

Model ARIMAX merupakan pengembangan dari model ARIMA. Pada model ARIMAX digunakan variabel tambahan berupa variabel eksogen. Variabel eksogen yang digunakan dapat berupa variabel *dummy* (non-metrik) maupun variabel deret waktu tertentu (metrik). Pada penelitian ini, variabel yang digunakan adalah variabel *dummy* berupa tren, musiman bulan,

dan efek variasi kalender. Model umum ARIMAX dapat ditunjukkan oleh (Lee, Suhartono, & Hamzah, 2010)

$$Y_t = \beta_0 + \beta_1 V_{1,t} + \beta_2 V_{2,t} + \dots + \beta_h V_{h,t} + N_t, \quad t = 1, 2, \dots, n, \quad (2.34)$$

$$\text{dan } N_t = \frac{\theta_q(B)}{\phi_p(B)} a_t, \quad (2.35)$$

dengan:

$V_{h,t}$  = variabel *dummy* ke  $h$ ,

$\phi_p(B)$  =  $(1 - \phi_1 B - \dots - \phi_p B^p)$ ,

$\theta_q(B)$  =  $(1 - \theta_1 B - \dots - \theta_q B^q)$ ,

$N_t$  = residual pada waktu ke- $t$  dari proses regresi *time series*,

$a_t$  = residual pada waktu ke- $t$  keseluruhan dari proses ARIMAX.

Dalam membentuk model ARIMAX, langkah awal yang dilakukan adalah pemodelan *time series regression* untuk menghilangkan efek dari variabel *dummy* yang digunakan. Residual dari model *time series regression* harus memenuhi asumsi *white noise*. Apabila asumsi tersebut belum dipenuhi, maka dilakukan pemodelan residual ( $N_t$ ) menggunakan ARIMA. Apabila residual ARIMA tidak memenuhi asumsi varians homogen, maka dapat dilakukan pemodelan GARCH.

## 2.6 Model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH)

Model GARCH merupakan pengembangan dari model ARCH. Pada model ARCH, heteroskedastisitas yang terjadi pada residual dapat dijelaskan oleh residual pada periode sebelumnya, sedangkan model GARCH dapat menjelaskan heteroskedastisitas yang dipengaruhi oleh varians pada periode sebelumnya juga dan residual pada periode sebelumnya. Bentuk umum model GARCH ( $r, s$ ) adalah:

$$Y_t = \mathbf{X}_t \boldsymbol{\beta} + N_t, \quad (2.36)$$

dengan:

$$N_t = \phi_1 N_{t-1} + \dots + \phi_p N_{t-p} + a_t,$$

$$a_t = \sigma_t e_t,$$

$$\sigma_t^2 = \theta_0 + \phi_1 \sigma_{t-1}^2 + \dots + \phi_r \sigma_{t-r}^2 + \theta_1 a_{t-1}^2 + \dots + \theta_s a_{t-s}^2,$$

$e_t$  merupakan variabel random yang identik dan independen dengan *mean* sebesar 0 dan varians sebesar 1. Estimasi parameter pada model GARCH dapat dilakukan dengan metode *Maximum Likelihood Estimation* (MLE) yang memaksimumkan fungsi *conditional likelihood* distribusi normal dari residual (Wei, 2006, pp. 373-374).

## 2.7 Quantile Regression

Analisis regresi merupakan suatu analisis untuk memodelkan hubungan antara dua variabel. Pada dasarnya, tujuan dari analisis regresi adalah untuk menemukan garis yang dapat mewakili setiap pasangan pengamatan. Analisis regresi dapat diaplikasikan pada peramalan, dengan mengasumsikan bahwa terdapat hubungan antara kejadian dimasa lalu dengan kejadian saat ini dan hubungan tersebut akan tetap ada hingga masa yang akan datang. Dengan demikian, pemilihan variabel independen merupakan hal yang penting dalam peramalan menggunakan analisis regresi (Guerard, 2013, pp. 19-20).

Pada umumnya, pengestimasian parameter dalam analisis regresi, dilakukan menggunakan estimasi *Ordinary Least Square* (OLS). Dengan estimasi OLS, salah satu asumsi yang harus dipenuhi adalah varians tiap pengamatan yang homogen (tidak terjadi heteroskedastisitas). Apabila terdapat pelanggaran asumsi tersebut, hasil taksiran parameter yang diperoleh akan menjadi tidak efisien, meskipun penaksir tersebut masih bersifat tak bias. Hal ini akan mengakibatkan koefisien taksiran menjadi kurang tepat dalam menaksir parameter (Andani & Widodo, 2016).

Regresi kuantil pertama kali diperkenalkan oleh Koenker dan Bassett pada tahun 1978 (Chen, 2007). Estimator dalam regresi kuantil diperoleh dengan mengestimasi nilai fungsi kuantil

dari suatu distribusi  $Y$  yang merupakan fungsi dari  $X$ . Distribusi data dapat menggambarkan karakteristik dari suatu data, sehingga dapat diperoleh gambaran mengenai pola data yang lebih lengkap. Regresi kuantil juga dapat digunakan untuk mengatasi permasalahan sebaran data yang tidak homogen.

### 2.7.1 Estimasi Parameter

Regresi kuantil merupakan pengembangan dari regresi klasik dengan estimasi *least square*. Persamaan umum regresi klasik dengan estimasi *least square* dengan  $p$ -variabel independen dapat dinyatakan sebagai:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}, \quad (2.37)$$

dengan:

$$\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}, \quad \mathbf{X} = \begin{bmatrix} x_{11} & x_{21} & \cdots & x_{p1} \\ x_{12} & x_{22} & \cdots & x_{p2} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1n} & x_{2n} & \cdots & x_{pn} \end{bmatrix}, \quad \boldsymbol{\beta} = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_p \end{bmatrix}, \quad \mathbf{u} = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix},$$

Penaksiran parameter regresi klasik dapat diperoleh dengan menyelesaikan persamaan

$$\min_{\boldsymbol{\beta}} \sum_{i=1}^n (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^2, \quad (2.38)$$

sehingga  $\hat{\mathbf{y}} = \mathbf{X}\hat{\boldsymbol{\beta}}$ , merupakan nilai estimasi untuk  $\mathbf{y}$  (Wong, 2016).

Regresi kuantil juga dapat dibentuk menggunakan konsep yang sama. Misal  $y$  merupakan variabel *random* yang memiliki fungsi distribusi  $F_Y$  dan  $\tau$  adalah bilangan *real*, dengan  $0 < \tau < 1$ . Kuantil ke-  $\tau$  dari  $F_Y$  dapat dinotasikan dengan  $Q(\tau)$ , dan dapat di definisikan sebagai:

$$Q(\tau) = \inf \{y : F(y) \geq \tau\}, \quad (2.39)$$

dengan  $F(y) = P(Y \leq y)$ . Sedangkan kuantil bersyarat ke- $\tau$  dari variabel  $y$  dengan variabel  $\mathbf{x}$ , sebagai kovariat dapat ditunjukkan dengan

$$\hat{Q}(\tau | \mathbf{X}) = \mathbf{X}\hat{\boldsymbol{\beta}}(\tau), \quad (2.40)$$

sehingga diperoleh persamaan untuk  $y$  pada kuantil ke- $\tau$  adalah:

$$\mathbf{y}(\tau) = \mathbf{X}\hat{\boldsymbol{\beta}}(\tau) + \mathbf{u}, \quad (2.41)$$

vektor  $\hat{\boldsymbol{\beta}}(\tau)$  merupakan estimasi parameter pada kuantil ke  $\tau$ .

Pendugaan parameter  $\hat{Q}(\tau | \mathbf{X}) = \mathbf{X}\hat{\boldsymbol{\beta}}(\tau)$  dapat diperoleh menggunakan

$$\hat{\boldsymbol{\beta}}(\tau) = \min_{\boldsymbol{\beta}} \left[ \sum_{\mathbf{y} \in \{r: y \geq \mathbf{X}\boldsymbol{\beta}\}} \tau |\mathbf{y} - \mathbf{X}\boldsymbol{\beta}| + \sum_{\mathbf{y} \in \{r: y < \mathbf{X}\boldsymbol{\beta}\}} (1 - \tau) |\mathbf{y} - \mathbf{X}\boldsymbol{\beta}| \right], \quad (2.42)$$

sehingga diperoleh nilai  $\hat{\boldsymbol{\beta}}(\tau)$  yang berbeda untuk setiap  $\tau$ . Persamaan (2.42) juga dapat dituliskan sebagai

$$\hat{\boldsymbol{\beta}}(\tau) = \underset{\boldsymbol{\beta}}{\operatorname{argmin}} \sum_{r=1}^n \boldsymbol{\rho}_{\tau}(\mathbf{u}), \quad (2.43)$$

$$\text{dengan } \boldsymbol{\rho}_{\tau}(\mathbf{u}) = \begin{cases} \tau \mathbf{u} & ; \mathbf{u} \geq 0 \\ (\tau - 1) \mathbf{u} & ; \mathbf{u} < 0 \end{cases},$$

Fungsi  $\boldsymbol{\rho}_{\tau}(\mathbf{u})$  merupakan *Loss function* (fungsi kerugian) dan  $\mathbf{u}$  merupakan residual dari hasil estimasi parameter (Koenker, 2005, pp. 5-6).

Dalam penyelesaian estimasi parameter regresi kuantil, diperlukan algoritma secara numerik untuk memperoleh estimastor konsisten dengan interval lebih sempit. Salah satu algoritma yang dapat digunakan adalah metode simpleks. Metode simpleks merupakan metode yang dapat menentukan kombinasi optimal dari tiga variabel atau lebih. Apabila dibandingkan dengan regresi OLS, regresi kuantil tidak membutuhkan asumsi khusus untuk nilai residualnya.



### 2.7.2 Pengujian Signifikansi Parameter

Pengujian parameter  $\beta$  untuk setiap kuantil dapat dilakukan menggunakan uji  $t$  dengan hipotesis

$$H_0 : \beta_j(\tau) = 0,$$

$$H_1 : \beta_j(\tau) \neq 0,$$

dengan  $j=1,2,...,p$ . Statistik uji  $t$  dapat diperoleh melalui

$$t_{hit}(\tau) = \frac{\hat{\beta}_j(\tau)}{SE(\hat{\beta}_j(\tau))}, \quad (2.44)$$

dengan  $\hat{\beta}_j(\tau)$  merupakan estimasi parameter  $\beta$  ke- $j$  pada kuantil ke- $\tau$  dan  $SE(\hat{\beta}_j(\tau))$  merupakan standar deviasi dari estimasi parameter  $\beta$  ke- $j$  pada kuantil ke- $\tau$ . Hipotesis pada  $H_0$  ditolak apabila  $|t_{hit}(\tau)| > t_{\frac{\alpha}{2}; n-p-1}$  (Goldameir, 2015).

## 2.8 Neural Network

*Neural network* merupakan model fleksibel pengembangan dari model regresi nonlinear dan model diskriminan, model *data reduction*, dan model *nonlinear dynamical systems*. *Neural network* terdiri dari *neuron* dalam jumlah besar. *Neuron* dalam model *neural network* ini merupakan elemen penyusun model nonlinier yang saling berhubungan secara kompleks dan disusun dalam beberapa lapisan. *Neural network* mampu mengolah data dalam jumlah besar dan dapat memiliki akurasi yang tinggi dalam melakukan prediksi (Sarle, 1994). Sebelum melakukan pemodelan menggunakan *neural network*, akan dilakukan pengujian linieritas pada data yang dianalisis. Pengujian linieritas dapat dilakukan menggunakan uji *lagrange multiplier* (LM), uji RESET, uji *Keenan*, dan uji *Tsay*. Pada penelitian ini, pengujian linieritas akan dilakukan menggunakan uji terasvirta.

Pengujian linieritas dengan uji LM didasarkan pada apabila penambahan variabel independen pada suatu model linier akan memberikan peningkatan  $R^2$  secara signifikan, maka model linier

tersebut kurang tepat dalam menggambarkan hubungan antara variabel independen dan variabel dependen. Dengan kata lain, bentuk fungsional dari data yang dianalisis bukan merupakan bentuk yang linier (Gujarati, 2004, pp. 523-524). Berikut adalah tahapan yang dilakukan dalam melakukan pengujian linieritas dengan uji LM.

1. Meregresikan  $Y_t$  pada  $X_t$  sehingga diperoleh model linier:

$$Y_t = \beta_0 + \beta_1 X_t + u_t, \quad (2.45)$$

Dari langkah pertama akan diperoleh  $\hat{u}_t$ .

2. Menambahkan variabel independen misal  $\hat{X}_t^2$  dan  $\hat{X}_t^3$  sehingga diperoleh model nonlinier:

$$\hat{u}_t = \beta_0 + \beta_1 X_t + \beta_2 \hat{X}_t^2 + \beta_3 \hat{X}_t^3 + v_t, \quad (2.46)$$

Dengan  $v$  merupakan komponen *error*.

3. Untuk ukuran sampel besar, perhitungan statistik uji secara asimtotis akan mengikuti distribusi  $\chi^2$ , dengan demikian, perhitungan statistik uji dapat dilakukan menggunakan:


$$\chi^2 = nR^2, \quad (2.47)$$

dengan  $n$  merupakan ukuran sampel, dan  $R^2$  merupakan koefisien determinasi dari model regresi persamaan (2.46).

4. Apabila  $\lambda^2_{hitung}$  yang diperoleh pada langkah 3 lebih besar daripada  $\lambda_{\alpha, df}$  maka dapat disimpulkan bahwa model linier pada persamaan (2.45) bukan merupakan model yang tepat. Dengan kata lain, terdapat permasalahan nonlinieritas antara variabel independen dan variabel dependen yang digunakan.

Apabila terdapat permasalahan nonlinieritas, maka model *neural network* dapat digunakan. Dalam peramalan, metode *neural network* yang banyak digunakan adalah *Feedforward Neural network* (FFNN). Pada FFNN, proses dimulai dari *input* yang diterima oleh *neuron*, dimana *neuron-neuron* ini dikelompokkan dalam *layer*. Informasi yang diterima dari *layer input* dilanjutkan ke *layer-layer* dalam FFNN secara berurutan hingga mencapai *layer output*. *Layer* yang berbeda diantara *input* dan *output* disebut *hidden layer* (Suhartono, 2007). *Input* yang

digunakan dalam *neural network* adalah *lag* dari observasi sebelumnya dengan *output* merupakan hasil peramalan. Pemilihan *input* dilakukan berdasarkan *lag* yang signifikan pada plot PACF data yang telah stasioner (Crone & Kourentzes, 2009). Pemilihan model *neural network* terbaik akan dilakukan menggunakan *cross validation*. Metode *cross validation* merupakan metode yang banyak digunakan dalam pemilihan model *neural network* (Anders & Korn, 1999). Model *feedforward neural network* dengan satu *hidden layer*, yang terdiri dari  $p$  *input*, satu *hidden layer* yang terdiri dari  $m$  unit dan dihubungkan ke *output*, dapat ditunjukkan pada Gambar 2.1 (Telbany, 2014).



**Gambar 2.1** Arsitektur *Neural Network*

Model yang dihasilkan oleh *neural network* dengan satu *hidden layer* dengan arsitektur seperti pada Gambar 2.1 dapat ditunjukkan pada (Taylor, 2000)

$$f(\mathbf{x}, \mathbf{v}, \mathbf{w}) = g_2 \left\{ \sum_{j=1}^m v_j g_1 \left[ \sum_{i=1}^p w_{ji} x_{it} \right] \right\}, \quad (2.48)$$

dengan  $\mathbf{w}$  merupakan pembobot yang menghubungkan *input layer* dengan *hidden layer*,  $\mathbf{v}$  merupakan pembobot yang menghubungkan *hidden layer* dengan *output layer*,  $g_1(\cdot)$  dan  $g_2(\cdot)$  merupakan fungsi aktivasi, sedangkan  $w_{ji}$  dan  $v_j$  merupakan bobot yang akan diestimasi. Pada umumnya fungsi aktivasi yang banyak digunakan adalah *sigmoid* dan linier.

## 2.9 *Quantile Regression Neural Network*

Regresi kuantil telah banyak diaplikasikan dalam permasalahan prediksi dengan melibatkan beberapa prediktor menggunakan model linier. Pada umumnya, seringkali terdapat hubungan nonlinier antara prediktor dan respon. Aplikasi regresi kuantil untuk model yang lebih fleksibel telah diperkenalkan oleh Taylor (2000). Taylor mengaplikasikan *Quantile Regression Neural Network* (QRNN) untuk mengatasi permasalahan nonlinier pada regresi kuantil. Dengan pendekatan *quantile regression neural network*, estimasi untuk pemodelan hubungan nonlinear dapat dilakukan tanpa menentukan bentuk fungsional yang tepat (Cannon, 2011). Sebelum *quantile regression neural network* diaplikasikan, akan dilakukan pengujian heteroskedastisitas pada model *neural network*. Model *neural network* pada dasarnya tidak memerlukan asumsi tertentu. Namun, secara statistik residual dari suatu model sebaiknya telah memenuhi independen dan identik. Apabila residual suatu model belum memenuhi karakteristik tersebut, maka pada dasarnya masih dapat dilakukan pemodelan kembali pada model yang digunakan.

Pengestimasian bobot pada *quantile regression neural network* akan dilakukan dengan meminimumkan jumlah eror dari nilai mutlak pembobot (Yeh, 2014). Model untuk *quantile regression neural network* dengan satu *hidden layer* dapat ditunjukkan pada (He, Xu, Wan, & Yang, 2016).

$$f(\mathbf{x}_i, \mathbf{v}(\tau), \mathbf{w}(\tau)) = g_2 \left\{ \sum_{j=0}^m v_j(\tau) g_1 \left[ \sum_{i=0}^p w_{ji}(\tau) x_{it} \right] \right\}, \quad (2.49)$$

dengan  $\mathbf{w}(\tau) = \{w_{ji}(\tau)\}_{j=1,2,\dots,m; i=1,2,\dots,p}$  merupakan pembobot yang menghubungkan *input layer* dengan *hidden layer*, sedangkan  $\mathbf{v}(\tau) = \{v_j(\tau)\}_{j=1,2,\dots,m}$  merupakan pembobot yang menghubungkan *hidden layer* dengan *output layer*.

Pada metode *quantile regression neural network*, kuantil ke- $\tau$  dapat diperoleh dengan meminimumkan fungsi:

$$F = \min_{\mathbf{v}(\tau), \mathbf{w}(\tau)} E_{\lambda}(\mathbf{v}(\tau), \mathbf{w}(\tau)). \quad (2.50)$$

Nilai  $E_{\lambda}(\mathbf{v}(\tau), \mathbf{w}(\tau))$  dapat diperoleh melalui persamaan:

$$\begin{aligned} E_{\lambda}(\mathbf{v}(\tau), \mathbf{w}(\tau)) &= \sum_{i=1}^p \rho_{\tau} [y_i(\tau) - f(\mathbf{x}_i, \mathbf{v}(\tau), \mathbf{w}(\tau))] + \lambda_1 \sum_{j,i} w_{ji}^2 + \\ &\quad \lambda_2 \sum_j v_j^2 \\ &= \sum_{t|y_t \geq f(\mathbf{x}_t, \mathbf{v}(\tau), \mathbf{w}(\tau))} \tau |y_t - f(\mathbf{x}_t, \mathbf{v}(\tau), \mathbf{w}(\tau))| + \\ &\quad \sum_{t|y_t < f(\mathbf{x}_t, \mathbf{v}(\tau), \mathbf{w}(\tau))} (1 - \tau) |y_t - f(\mathbf{x}_t, \mathbf{v}(\tau), \mathbf{w}(\tau))| + \\ &\quad \lambda_1 \sum_{j,i} w_{ji}^2 + \lambda_2 \sum_j v_j^2. \end{aligned}$$

dengan  $\lambda_1$  dan  $\lambda_2$  merupakan parameter regularisasi yang juga dapat menghindari terjadinya *overfitting*. Nilai optimal untuk  $\lambda_1$ ,  $\lambda_2$ , dan banyaknya unit pada *hidden layer* dapat dibentuk dengan menggunakan *cross validation* (Taylor, 2000). Dalam pengestimasiian pembobot optimal untuk  $\mathbf{w}(\tau)$  dan  $\mathbf{v}(\tau)$ , kuantil bersyarat dapat diperoleh melalui (He, Xu, Wan, & Yang, 2016).

$$\hat{Q}_Y(\tau | \mathbf{x}) = f(\mathbf{x}_t, \hat{\mathbf{v}}(\tau), \hat{\mathbf{w}}(\tau)). \quad (2.51)$$

## 2.10 Evaluasi Model

Evaluasi model dilakukan untuk mengetahui seberapa baik model yang terbentuk telah dapat meramalkan kejadian pada beberapa periode kedepan. Pada *quantile regression neural network*, nilai peramalan titik merupakan nilai estimasi untuk median, yakni pada kuantil 0,5. Evaluasi model dilakukan berdasarkan nilai keakuratan hasil ramalan menggunakan beberapa kriteria (Armstrong & Collopy, 1992; Wei, 2006; Gooijer & Hyndman, 2006). Pemilihan model terbaik dilakukan berdasarkan evaluasi tingkat kesalahan peramalan pada data *testing*. Perhitungan tingkat kesalahan peramalan untuk data *testing* dapat dilakukan melalui:

- a. *Root Mean Square Error* (RMSE), dengan perhitungan sebagai berikut,

$$RMSE = \sqrt{\frac{1}{M} \sum_{l=1}^M (Y_{n+l} - \hat{Y}_n(l))^2}. \quad (2.52)$$

- b. *Mean Absolute Error* (MAE), dengan perhitungan sebagai berikut,

$$MAE = \frac{\sum_{l=1}^M |Y_{n+l} - \hat{Y}_n(l)|}{M}. \quad (2.53)$$

- c. *Median Absolute Error* (MdAE), dengan perhitungan sebagai berikut,

$$MdAE = median(|Y_{n+l} - \hat{Y}_n(l)|). \quad (2.54)$$

- d. *Mean Absolute Percentage Error* (MAPE), dengan perhitungan sebagai berikut,

$$MAPE = 100 \times \frac{\sum_{l=1}^M \left| \frac{Y_{n+l} - \hat{Y}_n(l)}{Y_{n+l}} \right|}{M}. \quad (2.55)$$

- e. *Median Absolute Percentage Error* (MdAPE), dengan perhitungan sebagai berikut,

$$MdAPE = 100 \times median \left( \left| \frac{Y_{n+l} - \hat{Y}_n(l)}{Y_{n+l}} \right| \right). \quad (2.56)$$

dengan  $n$  merupakan banyaknya data *training*,  $M$  merupakan banyaknya data *testing*,  $Y_{n+l}$  merupakan data aktual ke  $l$  dan  $\hat{Y}_n(l)$  merupakan data ramalan  $l$  tahap kedepan.

Evaluasi model juga dilakukan berdasarkan kebaikan peramalan interval yang terbentuk. Salah satu kriteria yang banyak digunakan untuk menentukan akurasi dari estimator kuantil adalah persentase pengamatan yang termuat didalam interval tertentu (Taylor, 2000). Model yang memiliki performa lebih baik adalah model yang memiliki persentase data *testing*

yang termuat dalam peramalan interval tertentu lebih banyak namun intervalnya lebih sempit.

### **2.11 *Inflow dan Outflow Uang Kartal***

Uang merupakan alat yang memiliki empat fungsi dasar yakni sebagai alat tukar, alat penyimpan nilai, satuan hitung, dan ukuran pembayaran. Uang beredar dapat diartikan dalam arti sempit maupun dalam arti luas. Dalam arti sempit, uang beredar terdiri dari uang kartal dan uang giral dan disimbolkan dengan M1. Dalam arti luas, uang beredar terdiri dari uang kartal, uang giral, dan uang kuasi dan disimbolkan dengan M2. Uang kartal merupakan uang tunai yang berada di masyarakat dan siap dibelanjakan. Uang kartal terdiri dari uang kertas dan uang logam. Uang giral merupakan uang yang berada direkening giro pada Bank Umum. Uang kuasi merupakan uang yang disimpan dalam rekening tabungan dan deposito berjangka (Solikin & Suseno, 2002, pp. 10-14).

Kebijakan pengedaran uang di Indonesia bertujuan untuk memenuhi kebutuhan uang di masyarakat dalam jumlah nominal yang cukup, jenis pecahan yang sesuai, tepat waktu, dan dalam kriteria yang layak edar. Bank Indonesia mengupayakan tersedianya jumlah uang tunai di masyarakat secara cukup, dengan memperhatikan kesesuaian jenis pecahannya. Untuk ini, diperlukan perencanaan yang baik terutama dalam perencanaan pengadaan maupun perencanaan distribusinya, diantaranya adalah dengan menyusun Rencana Kebutuhan Uang (RKU). RKU merupakan prediksi perhitungan kebutuhan tambahan uang yang meliputi jumlah dan komposisi pecahan uang untuk memenuhi kebutuhan uang disusun dalam periode tertentu. Dalam penyusunan RKU terdapat beberapa faktor yang dijadikan pertimbangan, salah satunya adalah besarnya nilai *inflow* dan *outflow*.

Transaksi Penarikan Uang Rupiah (*outflow*) Uang Kartal merupakan informasi mengenai aliran uang kertas dan uang logam yang keluar dari Bank Indonesia. *Outflow* disusun dari gabungan transaksi uang kartal tiap pecahan yang keluar ke

perbankan dan masyarakat dari seluruh Satuan Kerja Kas Bank Indonesia. Penghitungan jumlah *outflow* diperoleh dari jumlah transaksi bayaran uang kartal dari BI ke perbankan dan non bank, penukaran uang keluar melalui loket BI dan kas keliling serta transaksi uang kartal keluar kas titipan.

Transaksi Penyetoran Uang Rupiah (*inflow*) Uang Kartal merupakan informasi mengenai aliran uang kertas dan uang logam yang masuk dari perbankan dan masyarakat ke Bank Indonesia. *Inflow* disusun dari gabungan transaksi uang kartal tiap pecahan yang masuk dari perbankan dan masyarakat ke seluruh Satuan Kerja Kas Bank Indonesia. Penghitungan jumlah *inflow* diperoleh dari jumlah transaksi setoran uang kartal dari BI ke perbankan dan non bank, penukaran uang masuk melalui loket BI dan kas keliling serta transaksi uang kartal masuk kas titipan (Departemen Statistik Bank Indonesia, 2016).

## **2.12 Penyusunan Rencana Kebutuhan Uang di Bank Indonesia**

Rencana Kebutuhan Uang (RKU) merupakan prediksi perhitungan kebutuhan tambahan uang yang meliputi jumlah dan komposisi pecahan uang untuk memenuhi kebutuhan uang disusun dalam periode tertentu. RKU digunakan sebagai dasar dalam penetapan rencana pengadaan uang dan rencana pendistribusian uang. Dalam menentukan nilai RKU, beberapa tahapan yang dilakukan adalah sebagai berikut.

- a. Melakukan prediksi *outflow* dan *inflow* secara Nasional dan di tiap-tiap Kantor Bank Indonesia. Prediksi dilakukan dengan menggunakan metode *Error Correction Model* (ECM) dan juga dekomposisi berdasarkan *tren historical data series*.
- b. Melakukan prediksi pemusnahan uang, persediaan kas akhir tahun berjalan dan kas minimum dengan menggunakan metode dekomposisi.
- c. Menyusun komposisi pecahan uang dan jadwal kebutuhan.
- d. Penetapan RKU yang menjadi acuan dalam penetapan Rencana Pengadaan Uang dan Bahan Uang, serta Rencana Distribusi Uang selama satu tahun.



Dalam rangka memenuhi kebutuhan uang kartal di masyarakat, secara periodik Bank Indonesia melakukan pengadaan uang dan bahan uang. Tujuan utama dari pengadaan uang dan bahan uang adalah menyediakan uang dalam jumlah yang cukup, sesuai denominasi, layak edar dan tepat waktu, dengan harga yang wajar, serta resiko pengadaan yang terkelola dengan baik (Bank Indonesia, 2010, pp. 88-90).

*(Halaman ini sengaja dikosongkan)*

## BAB III

### METODOLOGI PENELITIAN

#### 3.1 Sumber Data

Sumber data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari Bank Indonesia. Data yang digunakan adalah data *inflow* dan *outflow* nasional uang kertas tiap pecahan, yakni sebanyak tujuh pecahan. Dalam penelitian ini, periode data yang digunakan adalah Januari 2003 hingga Desember 2016. Data penelitian dibagi kedalam data *training* dan data *testing*. Data *training* yang digunakan adalah data *inflow* dan *outflow* pada periode Januari 2003 hingga Desember 2015, sedangkan data *testing* yang digunakan adalah data *inflow* dan *outflow* pada periode Januari 2016 hingga Desember 2016.

#### 3.2 Variabel Penelitian

Variabel penelitian yang digunakan dalam penelitian ini adalah variabel *inflow* dan *outflow* nasional uang kertas tiap pecahan yang ditunjukkan oleh Tabel 3.1.

**Tabel 3.1** Variabel Penelitian (dalam miliar rupiah)

<b>Data</b>	<b>Variabel</b>	<b>Keterangan</b>
<i>Inflow</i>	$Y_{1,t}$	pecahan Rp1.000,00 pada bulan ke- $t$
	$Y_{2,t}$	pecahan Rp2.000,00 pada bulan ke- $t$
	$Y_{3,t}$	pecahan Rp5.000,00 pada bulan ke- $t$
	$Y_{4,t}$	pecahan Rp10.000,00 pada bulan ke- $t$
	$Y_{5,t}$	pecahan Rp20.000,00 pada bulan ke- $t$
	$Y_{6,t}$	pecahan Rp50.000,00 pada bulan ke- $t$
	$Y_{7,t}$	pecahan Rp100.000,00 pada bulan ke- $t$
<i>Outflow</i>	$Y_{8,t}$	pecahan Rp1.000,00 pada bulan ke- $t$
	$Y_{9,t}$	pecahan Rp2.000,00 pada bulan ke- $t$
	$Y_{10,t}$	pecahan Rp5.000,00 pada bulan ke- $t$
	$Y_{11,t}$	pecahan Rp10.000,00 pada bulan ke- $t$
	$Y_{12,t}$	pecahan Rp20.000,00 pada bulan ke- $t$
	$Y_{13,t}$	pecahan Rp50.000,00 pada bulan ke- $t$
	$Y_{14,t}$	pecahan Rp100.000,00 pada bulan ke- $t$

Struktur data penelitian yang digunakan untuk *inflow* maupun *outflow* serta pembagian data penelitian menjadi data *training* dan *testing* dapat ditunjukkan pada Tabel 3.2.

**Tabel 3.2** Struktur Data

<i>Inflow</i>									
Data	Tahun	Bulan	Pecahan						
			$Y_1$	$Y_2$	$Y_3$	$Y_4$	$Y_5$	$Y_6$	$Y_7$
<i>Training</i>	2003	1	$Y_{1,1}$	$Y_{2,1}$	$Y_{3,1}$	$Y_{4,1}$	$Y_{5,1}$	$Y_{6,1}$	$Y_{7,1}$
	2003	2	$Y_{1,2}$	$Y_{2,2}$	$Y_{3,2}$	$Y_{4,2}$	$Y_{5,2}$	$Y_{6,2}$	$Y_{7,2}$
	2003	3	$Y_{1,3}$	$Y_{2,3}$	$Y_{3,3}$	$Y_{4,3}$	$Y_{5,3}$	$Y_{6,3}$	$Y_{7,3}$
	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
	2015	11	$Y_{1,155}$	$Y_{2,155}$	$Y_{3,155}$	$Y_{4,155}$	$Y_{5,155}$	$Y_{6,155}$	$Y_{7,155}$
	2015	12	$Y_{1,156}$	$Y_{2,156}$	$Y_{3,156}$	$Y_{4,156}$	$Y_{5,156}$	$Y_{6,156}$	$Y_{7,156}$
<i>Testing</i>	2016	1	$Y_{1,157}$	$Y_{2,157}$	$Y_{3,157}$	$Y_{4,157}$	$Y_{5,157}$	$Y_{6,157}$	$Y_{7,157}$
	2016	2	$Y_{1,158}$	$Y_{2,158}$	$Y_{3,158}$	$Y_{4,158}$	$Y_{5,158}$	$Y_{6,158}$	$Y_{7,158}$
	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
	2016	11	$Y_{1,167}$	$Y_{2,167}$	$Y_{3,167}$	$Y_{4,167}$	$Y_{5,167}$	$Y_{6,167}$	$Y_{7,167}$
	2016	12	$Y_{1,168}$	$Y_{2,168}$	$Y_{3,168}$	$Y_{4,168}$	$Y_{5,168}$	$Y_{6,168}$	$Y_{7,168}$
<i>Outflow</i>									
Data	Tahun	Bulan	Pecahan						
			$Y_8$	$Y_9$	$Y_{10}$	$Y_{11}$	$Y_{12}$	$Y_{13}$	$Y_{14}$
<i>Training</i>	2003	1	$Y_{8,1}$	$Y_{9,1}$	$Y_{10,1}$	$Y_{11,1}$	$Y_{12,1}$	$Y_{13,1}$	$Y_{14,1}$
	2003	2	$Y_{8,2}$	$Y_{9,2}$	$Y_{10,2}$	$Y_{11,2}$	$Y_{12,2}$	$Y_{13,2}$	$Y_{14,2}$
	2003	3	$Y_{8,3}$	$Y_{9,3}$	$Y_{10,3}$	$Y_{11,3}$	$Y_{12,3}$	$Y_{13,3}$	$Y_{14,3}$
	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
	2015	11	$Y_{8,155}$	$Y_{9,155}$	$Y_{10,155}$	$Y_{11,155}$	$Y_{12,155}$	$Y_{13,155}$	$Y_{14,155}$
	2015	12	$Y_{8,156}$	$Y_{9,156}$	$Y_{10,156}$	$Y_{11,156}$	$Y_{12,156}$	$Y_{13,156}$	$Y_{14,156}$
<i>Testing</i>	2016	1	$Y_{8,157}$	$Y_{9,157}$	$Y_{10,157}$	$Y_{11,157}$	$Y_{12,157}$	$Y_{13,157}$	$Y_{14,157}$
	2016	2	$Y_{8,158}$	$Y_{9,158}$	$Y_{10,158}$	$Y_{11,158}$	$Y_{12,158}$	$Y_{13,158}$	$Y_{14,158}$
	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
	2016	11	$Y_{8,167}$	$Y_{9,167}$	$Y_{10,167}$	$Y_{11,167}$	$Y_{12,167}$	$Y_{13,167}$	$Y_{14,167}$
	2016	12	$Y_{8,168}$	$Y_{9,168}$	$Y_{10,168}$	$Y_{11,168}$	$Y_{12,168}$	$Y_{13,168}$	$Y_{14,168}$

Pada umumnya, data *inflow* dan *outflow* mengandung pola tren, musiman, dan variasi kalender (Ahmad, Setiawan, Suhartono, & Masun, 2015; Setiawan, Suhartono, Ahmad, & Rahmawati, 2015). Dengan demikian, variabel *dummy* yang

digunakan dalam penelitian ini adalah variabel *dummy* tren, musiman, dan variasi kalender. Secara rinci, variabel *dummy* yang digunakan dapat ditunjukkan pada Tabel 3.3.

**Tabel 3.3** Variabel *Dummy* yang Digunakan

Variabel <i>dummy</i>	Keterangan
Tren	$t$ , dengan $t=1,2,\dots,n$
Musiman	$M_{1,t} = \begin{cases} 1, & \text{untuk Januari pada bulan ke-}t \\ 0, & \text{lainnya} \end{cases}$
	$M_{2,t} = \begin{cases} 1, & \text{untuk Februari pada bulan ke-}t \\ 0, & \text{lainnya} \end{cases}$
	$\vdots$
	$M_{12,t} = \begin{cases} 1, & \text{untuk Desember pada bulan ke-}t \\ 0, & \text{lainnya} \end{cases}$
Variasi Kalender	$V_{i,t} = \begin{cases} 1, & \text{untuk Idul Fitri pada minggu ke-}i \text{ bulan ke-}t, \\ & \text{dengan } i=1,2,3,4 \\ 0, & \text{lainnya} \end{cases}$
	$V_{i,t-1} = \begin{cases} 1, & \text{untuk bulan sebelum Idul Fitri (bulan ke-}t) \\ & \text{pada minggu ke-}i, \text{ dengan } i=1,2,3,4 \\ 0, & \text{lainnya} \end{cases}$
	$V_{i,t+1} = \begin{cases} 1, & \text{untuk bulan sesudah Idul Fitri (bulan ke-}t) \\ & \text{pada minggu ke-}i, \text{ dengan } i=1,2,3,4 \\ 0, & \text{lainnya} \end{cases}$

### 3.3 Langkah Analisis

Berikut adalah langkah-langkah analisis yang digunakan dalam melakukan penelitian ini berdasarkan tujuan penelitian yang telah dirumuskan.

1. Melakukan studi simulasi untuk mengetahui performa metode yang ARIMAX, *neural network* dan *quantile regression neural network* dalam mengatasi permasalahan heteroskedastisitas dan nonlinieritas. Studi simulasi dilakukan dengan membangkitkan data yang memiliki pola tren, musiman homogen dan heterogen, variasi kalender, serta *noise* yang linier dan nonlinier. Dengan demikian akan terbentuk empat skenario berdasarkan pola yang dibangkitkan. Kemudian dilakukan perbandingan performa ketiga berdasarkan kriteria RMSE, MAE, MdAE, MAPE, dan MdAPE.
2. Melakukan analisis statistika deskriptif pada setiap pecahan untuk mengetahui gambaran karakteristik data *inflow* dan *outflow*, dengan langkah sebagai berikut:
  - a. Melakukan perhitungan statistika deskriptif untuk data *inflow* dan *outflow*, meliputi *mean*, median, standar deviasi, *skewness*, dan kurtosis.
  - b. Melakukan identifikasi pola data *inflow* dan *outflow* melalui plot *time series*. Berdasarkan plot *time series*, diasumsikan bahwa data memiliki pola tren linier, musiman, variasi kalender, dan residual yang belum acak.
3. Melakukan pemodelan ARIMAX menggunakan regresi *time series* untuk data *inflow* dan *outflow* dengan tahapan sebagai berikut.
  - a. Menentukan variabel *dummy* yang digunakan. Berdasarkan identifikasi plot *time series* pada langkah 2b, diasumsikan bahwa data memiliki pola tren, musiman, variasi kalender, dan residual yang belum acak. Untuk tren, diasumsikan bahwa data *inflow* dan *outflow* memiliki pola tren linier, untuk musiman akan digunakan variabel *dummy* bulan dalam merekonstruksi pola musiman, dan untuk variasi kalender diasumsikan bahwa efek Idul Fitri berkaitan dengan minggu terjadinya hari raya pada bulan tersebut, satu bulan sebelumnya, dan satu bulan setelah Idul Fitri. Dengan demikian, variabel

*dummy* yang digunakan adalah variabel *dummy* untuk tren, musiman bulan, dan efek variasi kalender berupa hari raya Idul Fitri seperti ditunjukkan pada Tabel 3.3.

- b. Melakukan pemodelan *time series regression* untuk pola data tren, musiman, kalender variasi secara simultan sehingga diperoleh persamaan (2.1) seperti pada subbab 2.2 mengenai model regresi *time series* dengan variasi kalender.
- c. Melakukan pengujian apakah residual dari langkah 3b telah memenuhi asumsi *white noise*. Apabila residual telah memenuhi asumsi *white noise* maka model yang digunakan adalah model *time series regression* dan melanjutkan langkah analisis ke langkah nomor 3i. Apabila residual belum memenuhi asumsi *white noise*, maka dapat dilanjutkan ke langkah analisis nomor 3d.
- d. Memodelkan residual yang diperoleh dari regresi *time series* dengan menggunakan ARIMA dengan prosedur Box-Jenkins dengan tahapan identifikasi, estimasi, dan cek diagnosa sehingga diperoleh orde untuk model ARIMA.
- e. Melakukan pemodelan data *inflow* dan *outflow* menggunakan ARIMAX sehingga diperoleh persamaan (2.34) pada subbab 2.5 mengenai pemodelan dengan ARIMAX.
- f. Melakukan pemeriksaan apakah residual model ARIMAX mengandung efek ARCH/GARCH menggunakan pengujian *Lagrange Multiplier*.
- g. Apabila terdapat permasalahan heteroskedastisitas pada residual model ARIMA, maka dilanjutkan ke langkah nomor 2h. Apabila tidak terdapat efek ARCH/GARCH maka dapat dilanjutkan ke langkah nomor 3i.
- h. Memodelkan residual yang diperoleh dari ARIMAX menggunakan GARCH sehingga diperoleh model ARIMAX-GARCH.

- i. Melakukan peramalan titik dan interval untuk data *testing* menggunakan metode yang diperoleh pada langkah sebelumnya, kemudian menghitung tingkat kesalahan peramalan untuk data *testing*.
4. Membentuk model *neural network* untuk data *inflow* dan *outflow*.
  - a. Menentukan variabel *input* yang akan digunakan dalam *neural network*. Penentuan variabel *input* yang digunakan dapat dilakukan berdasarkan *lag* signifikan pada PACF dari variabel *output*.
  - b. Melakukan pengujian linieritas menggunakan uji terasvirta.
  - c. Menentukan banyaknya unit pada *hidden layer* menggunakan metode *cross validation*.
  - d. Melakukan estimasi parameter untuk pembobot *neural network*.
  - e. Melakukan pengujian apakah residual dari model *neural network* identik.
5. Membentuk model *quantile regression neural network* untuk data *inflow* dan *outflow* tiap pecahan. Dalam pembentukan model *quantile regression neural network*, nilai parameter regularisasi yang digunakan adalah 0, sedangkan  $\varepsilon$  untuk setiap iterasi adalah  $2^{-8}$ ,  $2^{-9}$ ,  $2^{-10}$ , ...,  $2^{-31}$ , dan  $2^{-32}$ , dengan fungsi aktivasi *tangent hyperbolic*. Terdapat 6 model QRNN yang digunakan, yakni:
  - i. Pemodelan satu tahap, dengan langkah sebagai berikut.
    - a. Menentukan nilai kuantil yang diestimasi. Kuantil yang digunakan pada penelitian ini adalah kuantil 0,025; 0,5; dan 0,975.
    - b. Melakukan pemilihan *input* yakni variabel *dummy* tren, musiman, dan variasi kalender, serta *lag*  $Y_t$  berdasarkan model terbaik pada metode *neural network* pada langkah 3.
    - c. Melakukan pemilihan *neuron* optimal. Kombinasi *neuron* yang digunakan adalah 1, 2, 3, 4, 5, 10, dan 15.



- d. Melakukan estimasi parameter dengan meminimumkan persamaan (2.50) pada subbab 2.9 mengenai *Quantile Regression Neural Network* menggunakan algoritma *non linier minimization* (nlm) *quasi Newton*.
- e. Melakukan peramalan titik dan interval.
- ii. Dekomposisi tren, musiman, dan variasi kalender, dengan langkah sebagai berikut.
  - a. Menentukan nilai kuantil yang diestimasi. Kuantil yang digunakan pada penelitian ini adalah kuantil 0,025; 0,5; dan 0,975.
  - b. Melakukan pemodelan *time series regression* (TSR) dengan variabel prediktor berupa tren, musiman, dan variasi kalender, dapat disebut pula *preprocessing* data. *Preprocessing* menggunakan dekomposisi dapat meningkatkan akurasi peramalan data yang mengandung pola tren dan musiman (Zhang & Qi, 2005; Suhartono & Subanar, 2006).
  - c. Melakukan perhitungan residual model TSR.
  - d. Melakukan identifikasi *input* model QRNN berdasarkan *lag* yang signifikan pada plot PACF residual TSR. Dengan demikian, *input* yang digunakan adalah *lag* dari residual TSR dan *output* berupa residual TSR.
  - e. Melakukan pemilihan *neuron* optimal. Kombinasi *neuron* yang digunakan adalah 1, 2, 3, 4, 5, 10, dan 15.
  - f. Melakukan estimasi parameter dengan meminimumkan persamaan (2.50) pada subbab 2.9 mengenai *Quantile Regression Neural Network* menggunakan algoritma *non linier minimization* (nlm) *quasi Newton*.
  - g. Melakukan peramalan titik dan interval. Hasil peramalan yang diperoleh merupakan penjumlahan dari hasil prediksi TSR dan QRNN.


- iii. Penggunaan *input* berupa nilai prediksi dari metode *neural network*. Penelitian mengenai penggunaan *input* berupa nilai prediksi dari metode tertentu telah dilakukan oleh Arunraj dan Ahrens (2015) yakni menggunakan model *quantile regression* dengan *input* berupa nilai prediksi ARIMA untuk meramalkan penjualan makanan, dan Taylor (2000) yang menggunakan model *quantile regression neural network* dengan *input* berupa nilai prediksi GARCH untuk meramalkan data *return* dari *exchange rate* di beberapa negara. Pada skema ini langkah yang dilakukan adalah sebagai berikut.
  - a. Menentukan nilai kuantil yang diestimasi. Kuantil yang digunakan pada penelitian ini adalah kuantil 0,025; 0,5; dan 0,975.
  - b. *Input* yang digunakan adalah nilai prediksi model *neural network* yang diperoleh pada langkah 4, sedangkan *outputnya* adalah data *inflow* dan *outflow*.
  - c. Melakukan pemilihan *neuron* optimal. Kombinasi *neuron* yang digunakan adalah 1, 2, 3, 4, 5, 10, dan 15.
  - d. Melakukan estimasi parameter dengan meminimumkan persamaan (2.50) pada subbab 2.9 mengenai *Quantile Regression Neural Network* menggunakan algoritma *non linier minimization* (nlm) *quasi Newton*
  - e. Melakukan peramalan titik dan interval.
- iv. Penggunaan *input* berupa nilai prediksi dari metode *neural network* dan *lag* yang masih signifikan pada residual model *neural network*, dengan langkah sebagai berikut.
  - a. Menentukan nilai kuantil yang diestimasi. Kuantil yang digunakan pada penelitian ini adalah kuantil 0,025; 0,5; dan 0,975.
  - b. Melakukan perhitungan nilai residual model *neural network* berdasarkan model *neural network* pada langkah 3.

- c. Melakukan identifikasi *lag* yang signifikan pada plot PACF residual model *neural network*.
- d. Melakukan pemilihan *input* model QRNN. *Input* yang digunakan adalah nilai prediksi model *neural network* yang diperoleh pada langkah 4 dan *lag*  $Y_t$  berdasarkan langkah c, sedangkan *output* nya adalah data *inflow* dan *outflow*.
- e. Melakukan pemilihan *neuron* optimal. Kombinasi *neuron* yang digunakan adalah 1, 2, 3, 4, 5, 10, dan 15.
- f. Melakukan estimasi parameter dengan meminimumkan persamaan (2.50) pada subbab 2.9 mengenai *Quantile Regression Neural Network* menggunakan algoritma *non linier minimization* (nlm) *quasi Newton*
- g. Melakukan peramalan titik dan interval.
- v. Penggunaan *input* berupa nilai prediksi dari metode *time series regression* dan *lag*  $Y_t$ , dengan langkah sebagai berikut.
  - a. Menentukan nilai kuantil yang diestimasi. Kuantil yang digunakan pada penelitian ini adalah kuantil 0,025; 0,5; dan 0,975.
  - b. Melakukan pemodelan *time series regression* dengan variabel prediktor berupa tren, musiman, dan variasi kalender, sehingga diperoleh nilai prediksi untuk model *time series regression*.
  - c. Identifikasi *lag* yang signifikan pada plot PACF dari data *inflow* dan *outflow*.
  - d. *Input* yang digunakan adalah nilai prediksi model *time series regression* yang diperoleh pada langkah b dan *lag*  $Y_t$  berdasarkan langkah c, sedangkan *output*nya adalah data *inflow* dan *outflow*.
  - e. Melakukan pemilihan *neuron* optimal. Kombinasi *neuron* yang digunakan adalah 1, 2, 3, 4, 5, 10, dan 15.
  - f. Melakukan estimasi parameter dengan meminimumkan persamaan (2.50) pada subbab 2.9

- mengenai *Quantile Regression Neural Network* menggunakan algoritma *non linier minimization* (nlm) *quasi Newton*
- g. Melakukan peramalan titik dan interval.
  - vi. Penggunaan *input* berupa nilai prediksi dari metode metode *time series regression* dan *lag* residual, dengan langkah sebagai berikut.
    - a. Menentukan nilai kuantil yang diestimasi. Kuantil yang digunakan pada penelitian ini adalah kuantil 0,025; 0,5; dan 0,975.
    - b. Melakukan pemodelan *time series regression* dengan variabel prediktor berupa tren, musiman, dan variasi kalender, sehingga diperoleh nilai prediksi untuk model *time series regression*.
    - c. Melakukan perhitungan residual model *time series regression*.
    - d. Melakukan identifikasi *lag* yang signifikan pada plot PACF dari residual *time series regression*.
    - e. *Input* yang digunakan adalah nilai prediksi model *time series regression* yang diperoleh pada langkah b dan *lag* residual berdasarkan langkah d, sedangkan *output* nya adalah data *inflow* dan *outflow*.
    - f. Melakukan pemilihan *neuron* optimal. Kombinasi *neuron* yang digunakan adalah 1, 2, 3, 4, 5, 10, dan 15.
    - g. Melakukan estimasi parameter dengan meminimumkan persamaan (2.50) pada subbab 2.9 mengenai *Quantile Regression Neural Network* menggunakan algoritma *non linier minimization* (nlm) *quasi Newton*
    - h. Melakukan peramalan titik dan interval.
  6. Melakukan perbandingan ketepatan hasil ramalan metode ARIMAX, *neural network* dan *quantile regression neural network* menggunakan kriteria RMSE, MAE, MdAE, MAPE, dan MdAPE dan kebaikan peramalan interval yang terbentuk.

7. Melakukan peramalan *inflow* dan *outflow* periode tahun 2017 untuk masing-masing pecahan berdasarkan metode terbaik pada langkah 6.
8. Menarik kesimpulan dan merumuskan saran.


Langkah-langkah analisis tersebut dapat digambarkan dalam diagram alir pada Gambar 3.1.



**Gambar 3.1** Diagram Alir Langkah-langkah Analisis


Pembentukan model *quantile regression neural network* pada langkah 5 dapat diilustrasikan kedalam gambar berikut.

1. Pemodelan satu tahap.




**Gambar 3.2** Ilustrasi Pembentukan Model QRNN Satu Tahap

## 2. Dekomposisi tren, musiman dan variasi kalender.



**Gambar 3.3** Ilustrasi Pembentukan Model QRNN dengan Dekomposisi


3. Penggunaan *input* berupa nilai prediksi model *neural network*.



**Gambar 3.4** Ilustrasi Pembentukan Model QRNN dengan *Input* berupa Prediksi NN




4. Penggunaan *input* berupa nilai prediksi model *neural network* dan *lag*  $Y_t$  dari PACF residual yang signifikan.




**Gambar 3.5** Ilustrasi Pembentukan Model QRNN dengan *Input* berupa Prediksi NN dan *lag*  $Y_t$

5. Penggunaan *input* berupa nilai prediksi metode *time series regression* dan lag  $Y_t$ .



**Gambar 3.6** Ilustrasi Pembentukan Model QRNN dengan *Input* Nilai Prediksi Metode TSR dan lag  $Y_t$

6. Penggunaan *input* berupa nilai prediksi metode *time series regression* dan *lag* residual.



**Gambar 3.7** Ilustrasi Pembentukan Model QRNN dengan *Input* Nilai Prediksi Metode TSR dan *lag*  $N_t$

*(Halaman ini sengaja dikosongkan)*

## BAB IV

### ANALISIS DAN PEMBAHASAN

Analisis dan pembahasan pada penelitian ini mencakup 2 kajian, yakni studi simulasi dan aplikasi pada data *real* yakni data *inflow* dan *outflow*. Studi simulasi dilakukan untuk mengetahui pola data yang mengandung heteroskedastisitas dan nonlinieritas serta untuk mengetahui performa metode ARIMAX, *neural network* dan *quantile regression neural network* dalam menangkap pola tersebut. Kemudian metode ARIMAX, *neural network* dan *quantile regression neural network* diaplikasikan pada data *inflow* dan *outflow* di Indonesia. Metode terbaik diperoleh dengan membandingkan nilai RMSE, MAE, MdAE, MAPE, dan MdAPE pada data *testing*. Selanjutnya dilakukan peramalan *inflow* dan *outflow* uang kertas tiap pecahan di Indonesia untuk 12 periode ke depan menggunakan metode terbaik.

#### 4.1 Studi Simulasi

Dalam melakukan identifikasi pola tren, musiman, dan variasi kalender perlu diketahui pola plot *time series* sehingga perlu dilakukan simulasi data yang memuat pola tren, musiman, dan variasi kalender. Pada penelitian ini, juga dilakukan identifikasi terjadinya heteroskedastisitas dan nonlinieritas. Simulasi juga dilakukan untuk mengetahui performa metode yang digunakan dalam menangkap pola heteroskedastisitas dan nonlinieritas. Data yang digunakan adalah simulasi data *outflow* periode bulan Januari tahun 2001 hingga bulan Desember tahun 2016. Tanggal kejadian hari raya ditunjukkan pada Tabel 4.1.

Perhitungan minggu menurut Bank Indonesia adalah minggu pertama meliputi tanggal 1 sampai dengan tanggal 7, minggu kedua untuk meliputi 8 sampai dengan tanggal 15, minggu ketiga meliputi tanggal 16 sampai dengan tanggal 23, dan minggu keempat meliputi tanggal 24 sampai dengan tanggal terakhir pada bulan tersebut (Bank Indonesia, 2001).

**Tabel 4.1** Kejadian Idul Fitri Tahun 2001 hingga 2016

Tahun	Tanggal Idul Fitri	Idul Fitri pada minggu ke- <i>i</i>	Variabel <i>Dummy</i>		
			$V_{i,t-1}$	$V_{i,t}$	$V_{i,t+1}$
2001	17-18 Desember	Minggu ke-3	November	Desember	Januari
2002	6-7 Desember	Minggu ke-1	November	Desember	Januari
2003	25-26 November	Minggu ke-4	Oktober	November	Desember
2004	13-14 November	Minggu ke-2	Oktober	November	Desember
2005	03-04 November	Minggu ke-1	Oktober	November	Desember
2006	23-24 Oktober	Minggu ke-4	September	Oktober	November
2007	12-13 Oktober	Minggu ke-2	September	Oktober	November
2008	1-2 Oktober	Minggu ke-1	September	Oktober	November
2009	20-21 September	Minggu ke-3	Agustus	September	Oktober
2010	09-10 September	Minggu ke-2	Agustus	September	Oktober
2011	30-31 Agustus	Minggu ke-4	Juli	Agustus	September
2012	18-19 Agustus	Minggu ke-3	Juli	Agustus	September
2013	08-09 Agustus	Minggu ke-2	Juli	Agustus	September
2014	28-29 Juli	Minggu ke-4	Juni	Juli	Agustus
2015	19-20 Juli	Minggu ke-3	Juni	Juli	Agustus
2016	06-07 Juli	Minggu ke-1	Juni	Juli	Agustus

#### 4.1.1 Pembangkitan Data Simulasi

Model yang digunakan dalam simulasi data *time series* yang memuat tren, musiman, dan variasi kalender berupa hari raya Idul Fitri adalah

$$Y_t = T_t + M_t + V_t + N_t, \quad (4.1)$$

dengan :

a. Komponen untuk tren

$$T_t = \beta t, \quad (4.2)$$

Koefisien untuk tren yang digunakan dalam seluruh skenario adalah sama, yakni  $\beta=0,1$ .

b. Komponen untuk musiman bulan

$$M_t = \gamma_1 M_{1,t} + \gamma_2 M_{2,t} + \dots + \gamma_{12} M_{12,t}$$

Untuk komponen musiman bulan, terdapat 2 jenis pola musiman yang digunakan, yakni pola musiman homogen dan pola musiman heterogen. Persamaan untuk pola musiman homogen dapat ditunjukkan oleh persamaan (4.3).

$$M_{1,t} = 20M_{1,t} + 23M_{2,t} + 25M_{3,t} + 23M_{4,t} + 20M_{5,t} + 15M_{6,t} + 10M_{7,t} + 7M_{8,t} + 5M_{9,t} + 7M_{10,t} + 10M_{11,t} + 15M_{12,t}, \quad (4.3)$$

Sedangkan pada pola musiman heterogen, koefisien  $\gamma_{j,t} \sim U(a_j, b_j)$ , untuk  $j=1,2,...,12$ . Untuk memperoleh data yang memiliki heteroskedastisitas pada pola musiman, dilakukan pembangkitan data yang berdistribusi *uniform* dengan rentang yang berbeda dan *mean* dari distribusi *uniform* merupakan koefisien yang digunakan dalam model musiman homogen. Rentang yang digunakan untuk membangkitkan data musiman yang bersifat heterogen dapat ditunjukkan oleh Tabel 4.2.

**Tabel 4.2** Nilai a dan b untuk Simulasi Data Heterogen pada Musiman

Bulan ke-j	$U(a_j; b_j)$	Bulan ke-j	$U(a_j; b_j)$
1	$U(14;26)$	7	$U(4;14)$
2	$U(15;31)$	8	$U(4,5;9,5)$
3	$U(15;35)$	9	$U(2,5;7,5)$
4	$U(16;30)$	10	$U(4,5;9,5)$
5	$U(14;26)$	11	$U(5;15)$
6	$U(9;21)$	12	$U(9;21)$

Berdasarkan pembangkitan data yang berdistribusi *uniform* dengan rentang yang berbeda maka diperoleh  $M_{2,t}$  yang memiliki pola heterogen dalam musiman.

c. Komponen untuk variasi kalender

$$V_t = \delta_1 V_{1,t} + \delta_2 V_{2,t} + \delta_3 V_{3,t} + \delta_4 V_{4,t} + \omega_1 V_{1,t-1} + \omega_2 V_{2,t-1} + \omega_3 V_{3,t-1} + \omega_4 V_{4,t-1}, \quad (4.4)$$

Model simulasi yang digunakan merupakan model simulasi data *outflow*. Dengan demikian, efek variasi kalender yang digunakan adalah pada saat terjadinya hari raya Idul Fitri dan satu bulan sebelum terjadinya hari raya Idul Fitri. Koefisien untuk variasi kalender yang digunakan dalam seluruh skenario ditunjukkan oleh persamaan (4.5),

$$V_t = 23V_{1,t} + 37V_{2,t} + 44V_{3,t} + 48V_{4,t} + 56V_{1,t-1} + 42V_{2,t-1} + 34V_{3,t-1} + 30V_{4,t-1}, \quad (4.5)$$


d. *Noise*

*Noise* yang digunakan dalam simulasi terdiri dari *noise* yang memiliki pola linier yang ditunjukkan oleh persamaan (4.6) dan pola nonlinier yang ditunjukkan oleh persamaan (4.7).

$$N_{1,t} = 0,7N_{1,t-1} + a_t, \text{ dengan } a_t \sim IIDN(0,1). \quad (4.6)$$

$$N_{2,t} = 6,5N_{t-1} \cdot \exp(-0,25N_{t-1}^2) + a_t, \text{ dengan } a_t \sim IIDN(0,1). \quad (4.7)$$

Gambar 4.1 menunjukkan plot *time series* yang memuat masing-masing pola yakni pola tren, variasi kalender, musiman homogen dan heterogen, serta *noise* berpola linier dan nonlinier.



**Gambar 4.1** Pola untuk Dekomposisi *Pattern*.

Berdasarkan Gambar 4.1 terlihat bahwa dengan adanya pola tren akan mengakibatkan kenaikan data pengamatan seiring pertambahan waktu. Pola musiman akan mengakibatkan pada bulan yang sama, data pengamatan akan cenderung memiliki nilai yang sama. Adanya heteroskedastisitas pada musiman menyebabkan pola musiman yang terbentuk menjadi kurang




dapat diidentifikasi melalui plot *time series*. Apabila terdapat efek variasi kalender, plot *time series* dari data akan menunjukkan pada waktu-waktu tertentu, yakni pada waktu terjadinya kejadian khusus, data pengamatan akan bernilai lebih tinggi dibandingkan dengan pengamatan pada waktu lainnya. Hal ini akan mengakibatkan model dengan efek variasi kalender akan menghasilkan akurasi data *testing* yang lebih baik apabila dibandingkan dengan model tanpa variasi kalender. Penelitian yang telah dilakukan oleh Lee, Suhartono, dan Hamzah (2010) menunjukkan bahwa peramalan data penjualan pakaian muslim menggunakan metode ARIMAX dengan variasi kalender akan menghasilkan peramalan data *testing* yang lebih baik dibandingkan menggunakan metode dekomposisi, *seasonal ARIMA*, maupun *neural network*.

Hari raya Idul Fitri yang terjadi pada minggu yang berbeda juga memiliki efek yang berbeda pada peningkatan data simulasi. Apabila hari raya Idul Fitri terjadi pada minggu pertama, maka kenaikan data simulasi akan lebih rendah dibandingkan dengan hari raya Idul Fitri yang terjadi pada minggu kedua, ketiga, dan keempat. Hari raya Idul Fitri yang terjadi pada minggu pertama ditunjukkan oleh garis warna biru, pada minggu kedua warna hijau, pada minggu ketiga warna hitam, dan pada minggu keempat warna merah.

*Noise* yang mengikuti pola linier dan nonlinier tidak memiliki perbedaan yang signifikan pada plot *time series* nya. Dengan demikian, untuk mengidentifikasi pola *noise*, dilakukan melalui plot antara *noise* pada waktu ke- $t$  dengan *noise* pada waktu ke- $t-1$ . Gambar 4.2 menunjukkan plot *noise* pada waktu ke- $t$  dengan *noise* pada waktu ke- $t-1$  untuk pola linier dan pola nonlinier.

Berdasarkan plot pada Gambar 4.2 terlihat bahwa untuk *noise* yang memiliki pola linier menghasilkan plot yang berbentuk linier pula. Sedangkan *noise* yang memiliki pola nonlinier menghasilkan plot yang mengikuti pola nonlinier.




**Gambar 4.2** Plot *Noise* pada waktu ke- $t$  dengan *Noise* pada waktu ke- $t-1$  untuk Pola Linier (a) dan Nonlinier (b).

Model *time series regression* seperti pada persamaan (4.1) dapat pula disebut dengan model dekomposisi *pattern*. Simulasi menggunakan model dekomposisi *pattern* dilakukan dengan menggunakan kombinasi musiman yang homogen dan heterogen, serta residual yang bersifat linier dan nonlinier. Dengan demikian diperoleh 4 skenario yakni model musiman homogen dengan *noise* linier, model musiman heterogen dengan *noise* linier, model musiman homogen dengan *noise* nonlinier, dan model musiman heterogen dengan *noise* nonlinier.


#### 4.1.1.1 Skenario 1

Pada skenario 1, pola musiman disimulasikan bersifat homogen ( $M_{1,t}$ ) dan *noise* dari regresi *time series* merupakan deret yang belum *white noise* dan mengikuti model linier ( $N_{1,t}$ ). Gambar 4.3 merupakan hasil simulasi untuk model pada skenario 1:



**Gambar 4.3** Plot *Time Series* Skenario 1.

Berdasarkan plot *time series* pada Gambar 4.3, terlihat bahwa pada simulasi skenario 1, pola tren, musiman, dan variasi kalender dapat teridentifikasi melalui plot *time series* saja. Pada saat terjadinya hari raya Idul Fitri, besarnya *outflow* pada bulan tersebut dan satu bulan setelahnya akan memiliki nilai yang jauh lebih tinggi dibandingkan bulan-bulan lainnya. Namun untuk mengetahui apakah pola musiman yang terdapat pada model simulasi bersifat homogen atau heterogen, tidak dapat dilakukan melalui plot *time series*. Dengan demikian, identifikasi heteroskedastisitas pada pola musiman dilakukan melalui *boxplot* seperti pada Gambar 4.4.



**Gambar 4.4** Identifikasi Heteroskedastisitas dengan *Boxplot*.


Gambar 4.4(a) merupakan *boxplot* dari data simulasi yang dipisahkan berdasarkan bulan. Namun adanya kejadian hari raya Idul Fitri pada bulan tertentu mengakibatkan variasi yang besar pada bulan tersebut, sehingga untuk mengidentifikasi pola musiman, kejadian hari raya Idul Fitri dan satu bulan sebelumnya perlu dipisahkan dari bulan-bulan lainnya seperti pada Gambar

4.4(b). Pada Gambar 4.4(b) efek hari raya Idul Fitri telah dipisahkan sehingga variasi pada pola musiman tidak lagi dipengaruhi oleh kejadian hari raya Idul Fitri. Namun demikian, variasi pola musiman masih dipengaruhi oleh tren. Pada bulan mendekati akhir tahun, koefisien untuk pola tren akan lebih besar dibandingkan pada bulan diawal tahun, sehingga pola tren juga perlu dihilangkan untuk mengidentifikasi pola musiman, seperti *boxplot* pada Gambar 4.4(c). Pada Gambar 4.4(c), sudah tidak terdapat pengaruh kejadian hari raya dan pola tren, sehingga variasi pola musiman dapat diidentifikasi. Pada Gambar 4.4(d) *boxplot* untuk variasi kalender tidak disertakan, sehingga identifikasi pola musiman dapat dilakukan secara lebih jelas.


Berdasarkan Gambar 4.4 (d) terlihat bahwa variasi di setiap bulan cenderung sama. Hal ini menunjukkan bahwa identifikasi pola musiman telah sesuai dengan model simulasi yang dibangkitkan, yakni memiliki pola musiman yang homogen.

#### 4.1.1.2 Skenario 2

Pada skenario 2, pola musiman disimulasikan bersifat heterogen ( $M_{2,t}$ ) dan *noise* dari regresi *time series* merupakan deret yang belum *white noise* dan mengikuti model linier ( $N_{1,t}$ ). Gambar 4.5 dan Gambar 4.6 merupakan hasil simulasi untuk model pada skenario 2:



**Gambar 4.5** Plot *Time Series* Skenario 2.




**Gambar 4.6** *Boxplot* tanpa Tren dan Variasi Kalender untuk Skenario 2.

Identifikasi heteroskedastisitas pada pola musiman tidak dapat hanya dilakukan menggunakan plot *time series*. Gambar 4.5


merupakan data yang memiliki heteroskedastisitas pada pola musiman. Apabila dibandingkan dengan Gambar 4.3, tidak terdapat perbedaan signifikan antara kedua gambar tersebut, sehingga identifikasi heteroskedastisitas pada pola musiman perlu dilakukan menggunakan *boxplot* untuk setiap bulan dengan menghilangkan pola tren dan kalender variasi terlebih dahulu, seperti ditunjukkan pada Gambar 4.6. Apabila dibandingkan dengan *boxplot* pada Gambar 4.4 (d) tentunya dapat diidentifikasi permasalahan heteroskedastisitas pada skenario 2. Pada Gambar 4.6 terlihat bahwa terdapat perbedaan variasi setiap bulannya. Variasi tertinggi terdapat pada bulan Maret, sedangkan variasi terkecil terdapat pada bulan Agustus. Perbedaan variasi yang diperoleh telah sesuai dengan rancangan skenario yang dibuat, yakni pada bulan Agustus, September, dan Oktober memiliki rentang terkecil dan pada bulan Maret memiliki rentang terbesar.

#### 4.1.1.3 Skenario 3

Pada skenario 3, pola musiman disimulasikan bersifat homogen ( $M_{1,t}$ ) dan *noise* dari regresi *time series* merupakan deret yang belum *white noise* dan mengikuti model nonlinier ESTAR ( $N_{2,t}$ ). Gambar 4.7 dan Gambar 4.8 merupakan hasil simulasi untuk model pada skenario 3:



**Gambar 4.7** Plot *Time Series*  
Skenario 3.




**Gambar 4.8** *Boxplot* tanpa Tren dan  
Variasi Kalender untuk Skenario 3.

Adanya pola nonlinier pada residual ARIMAX akan mengakibatkan bentuk pola musiman kurang dapat diidentifikasi melalui plot *time series*, seperti pada Gambar 4.7. Pola nonlinier


juga tidak dapat diidentifikasi berdasarkan plot *time series* maupun *boxplot* bulanan tanpa mengandung pola tren dan variasi kalender. Sehingga untuk mengidentifikasi pola nonlinier pada data, perlu menggunakan plot antara *noise* pada waktu ke- $t$  dengan *noise* pada waktu ke  $t-1$ . Selain itu juga dapat dilakukan pengujian linieritas dengan menggunakan uji terasvirta.

#### 4.1.1.4 Skenario 4

Pada skenario 4, pola musiman disimulasikan bersifat heterogen ( $M_{2,t}$ ) dan *noise* dari regresi *time series* merupakan deret yang belum *white noise* dan mengikuti model nonlinier ESTAR ( $N_{2,t}$ ). Gambar 4.9 dan Gambar 4.10 merupakan hasil simulasi untuk model pada skenario 4:



**Gambar 4.9** Plot Time Series Skenario 4.



**Gambar 4.10** Boxplot tanpa Tren dan Variasi Kalender untuk Skenario 4.

Pada skenario 4, pola musiman juga tidak dapat diidentifikasi berdasarkan plot *time series*. Pada *boxplot* bulanan, terlihat bahwa terdapat perbedaan variasi pada setiap bulannya. Identifikasi pola nonlinier pada data juga dapat dilakukan melalui pengujian linieritas antara *noise* pada waktu ke- $t$  dengan *noise* pada waktu ke- $t-1$ .

#### 4.1.2 Peramalan dengan ARIMAX

Langkah awal dalam peramalan menggunakan metode ARIMAX adalah melakukan pemodelan *time series regression* dengan variabel prediktor berupa variabel *dummy* tren, musiman bulan, dan variasi kalender. Pemodelan *time series regression*


bertujuan untuk menghilangkan pola tren, musiman, dan variasi kalender. Kemudian, apabila residual yang dihasilkan belum memenuhi asumsi *white noise*, maka residual dari model *time series regression* akan dimodelkan dengan ARIMA. Dengan menggunakan metode ARIMA, model terbaik yang diperoleh untuk setiap skenario dan replikasinya ditunjukkan oleh Tabel 4.3, dengan data simulasi  $Y_{ij}$  merupakan data simulasi untuk skenario ke- $i$  dan replikasi ke- $j$ .

**Tabel 4.3** Model ARIMA untuk Data Simulasi


Data simulasi	Model	Residual White Noise
Y_11	ARIMA (1,0,0)	Ya
Y_12	ARIMA (1,0,0)	Ya
Y_13	ARIMA (1,0,0)	Ya
Y_14	ARIMA (1,0,0)	Ya
Y_15	ARIMA (1,0,0)	Ya
Y_21	ARIMA ([1,13],0,0)	Ya
Y_22	ARIMA ([13],0,0) - GARCH (1,0)	Tidak
Y_23	ARIMA (1,0,0)(2,0,0) <sup>12</sup> - GARCH ([12],[12])	Tidak
Y_24	ARIMA (0,0,0) - GARCH (1,0)	Tidak
Y_25	ARIMA (0,0,0) - GARCH ([12],[12])	Tidak
Y_31	ARIMA (1,0,0) - GARCH (1,1)	Tidak
Y_32	ARIMA (1,0,0) - GARCH (1,0)	Tidak
Y_33	ARIMA (1,0,0) - GARCH (1,1)	Tidak
Y_34	ARIMA (1,0,0) - GARCH (1,0)	Tidak
Y_35	ARIMA (1,0,0) - GARCH (1,2)	Tidak
Y_41	<i>Time series regression</i>	Ya
Y_42	<i>Time series regression</i>	Ya
Y_43	<i>Time series regression</i>	Ya
Y_44	<i>Time series regression</i>	Ya
Y_45	<i>Time series regression</i>	Ya

Tabel 4.3, menunjukkan bahwa pada skenario 1 diperoleh residual model ARIMAX yang telah *white noise*, sesuai dengan skenario yang telah ditetapkan. Pada skenario 2, pola heteroskedastisitas musiman menyebabkan residual ARIMAX memiliki varians yang tidak homogen. Pola heteroskedastisitas teridentifikasi disekitar *lag* 12. Hal ini menunjukkan bahwa pola heteroskedastisitas terjadi pada pola musiman, sesuai dengan skenario yang telah ditetapkan. Sehingga perlu dilanjutkan pemodelan menggunakan GARCH. Pada skenario 3 adanya pola nonlinier dapat mengakibatkan residual model ARIMAX

memiliki varians yang tidak homogen, pola heteroskedastisitas teridentifikasi pada hampir semua *lag*. Sehingga, pola heteroskedastisitas tidak terjadi pada pola musimannya. Pada skenario 4, model *time series regression* menghasilkan residual *white noise*, yang menunjukkan bahwa adanya heteroskedastisitas dan nonlinieritas mengakibatkan residual tidak dapat dimodelkan kembali. Perbandingan data *testing* dan data ramalan dengan ARIMAX untuk setiap skenario pada replikasi pertama ditunjukkan pada Gambar 4.11.







**Gambar 4.11** Perbandingan Data Aktual dan Ramalan Model ARIMAX untuk Simulasi Replikasi Pertama pada Skenario 1 (a), Skenario 2 (b), Skenario 3 (c), dan Skenario 4 (d).

Gambar 4.11 menunjukkan bahwa model ARIMAX dapat mengikuti pola data simulasi dengan baik, terutama untuk skenario 1 yang tidak memiliki heteroskedastisitas dalam musiman dan residual yang linier. Untuk skenario 2 dan 4, model ARIMAX masih dapat menangkap pola variasi kalender, namun pada pengamatan tertentu, yakni data *testing* ketiga, ramalan yang dihasilkan cenderung berbeda dengan data aktual. Hal ini dapat disebabkan oleh adanya pola heteroskedastisitas musiman pada kedua skenario tersebut. Sedangkan pada skenario 3, metode ARIMAX juga dapat menangkap pola data aktual dengan baik. Setelah diperoleh model terbaik untuk setiap skenario dan replikasi, akan dihitung kriteria evaluasi yakni RMSE, MAE, MdAE, MAPE, dan MdAPE untuk mengetahui performa metode ARIMAX dalam memodelkan keempat skenario. Nilai kriteria untuk setiap model dapat ditunjukkan pada Tabel 4.4.


**Tabel 4.4** Kriteria Evaluasi Model ARIMAX untuk Data Simulasi

Data	Training					Testing				
	RMSE	MAE	MdAE	MdAPE	MAPE	RMSE	MAE	MdAE	MdAPE	MAPE
Y_11	0,91	0,71	0,58	2,08	2,94	2,25	1,56	0,98	3,14	3,98
Y_12	1,24	1,00	0,80	2,89	4,13	1,66	1,12	0,43	1,07	3,81
Y_13	1,16	0,93	0,84	2,69	3,68	1,70	1,38	1,38	3,76	3,97
Y_14	1,19	0,92	0,71	2,58	3,82	1,64	1,25	0,73	1,89	3,61
Y_15	1,28	1,02	0,83	3,10	4,25	1,83	1,41	1,15	2,92	3,87
Y_21	3,52	2,83	2,50	9,32	11,66	4,39	3,35	2,64	6,33	7,87
Y_22	3,62	2,84	2,15	9,28	11,14	4,62	3,51	2,72	6,61	8,69
Y_23	3,42	2,79	2,44	8,89	11,02	4,18	3,45	3,12	7,96	8,70
Y_24	3,55	2,68	2,06	7,35	10,98	3,97	2,92	2,81	6,89	7,08
Y_25	3,56	2,83	2,40	8,61	11,64	4,32	3,30	2,20	6,42	8,48


**Tabel 4.4** Kriteria Evaluasi Model ARIMAX untuk Data Simulasi (*Lanjutan*)

Data	Training					Testing				
	RMSE	MAE	MdAE	MdAPE	MAPE	RMSE	MAE	MdAE	MdAPE	MAPE
Y_31	2,87	2,34	2,15	6,70	10,91	3,18	2,55	2,65	4,79	7,08
Y_32	2,96	2,35	1,83	6,74	11,13	3,06	2,59	2,40	8,20	8,20
Y_33	3,00	2,41	2,05	7,12	11,31	3,00	2,57	2,35	7,57	7,43
Y_34	2,94	2,33	2,02	6,55	10,75	3,75	3,13	3,02	8,35	9,07
Y_35	3,05	2,41	1,87	6,88	12,18	3,05	2,51	2,55	6,46	6,89
Y_41	4,34	3,57	3,14	11,33	16,05	4,20	3,71	3,22	10,11	9,80
Y_42	4,38	3,52	3,18	11,84	15,20	4,45	3,81	3,44	10,84	10,13
Y_43	4,36	3,48	2,95	11,05	15,37	4,29	3,73	2,91	8,31	9,90
Y_44	4,30	3,42	2,85	10,81	15,04	4,62	3,99	4,11	10,91	10,54
Y_45	4,35	3,52	3,21	10,71	16,06	4,37	3,74	3,36	9,35	9,65

Tabel 4.4 dapat diilustrasikan pada Gambar 4.12 untuk memudahkan dalam melakukan perbandingan kebaikan model yang terbentuk.


**Gambar 4.12** Perbandingan Kriteria Evaluasi Model ARIMAX Data Simulasi.

Berdasarkan Gambar 4.12, dapat diketahui bahwa nilai MAE dan MdAE untuk keempat skenario cenderung sama. Hal ini menunjukkan bahwa data residual ARIMAX memiliki pola yang simetris, sehingga penggunaan kriteria berbasis *mean* maupun *median* dapat digunakan untuk mengevaluasi kebaikan model. Untuk membandingkan kemampuan model ARIMAX dalam menangkap pola heterokedastisitas musiman dan nonlinieritas, maka dilakukan perbandingan setiap skenario dan replikasi pada data *training* maupun *testing* menggunakan kriteria RMSE yang ditunjukkan oleh Gambar 4.13.



**Gambar 4.13** Perbandingan RMSE Model ARIMAX Data Simulasi.

Gambar 4.12 menunjukkan bahwa untuk data *training* dan *testing*, model ARIMAX dapat menangkap pola musiman homogen dan residual linier (skenario 1) dengan baik. Nilai RMSE untuk skenario 1 berada jauh dibawah skenario lainnya. RMSE yang dihasilkan oleh model skenario 3 lebih rendah dibandingkan skenario 2 dan 4 untuk data *training* maupun *testing*. Nilai RMSE untuk skenario 2 dan 4 untuk data *testing* cenderung tinggi apabila dibandingkan dengan skenario lainnya. Dengan demikian, model ARIMAX kurang dapat menangkap pola heteroskedastisitas pada musiman. Selanjutnya akan dianalisis perbandingan RMSE data *training* dan *testing* untuk seluruh skenario, yang dapat ditunjukkan pada Gambar 4.14.



**Gambar 4.14** Perbandingan RMSE ARIMAX Data *Training-Testing* untuk Data Simulasi.

Berdasarkan Gambar 4.14, terlihat bahwa pola data dengan residual nonlinier cenderung memiliki RMSE yang sama untuk data *training* dan data *testing*nya. Sedangkan data yang dengan residual linier, RMSE untuk data *testing* lebih tinggi dibandingkan dengan data *training*, baik untuk pola homogen maupun heterogen dalam musiman. Berdasarkan Gambar 4.12, nilai RMSE data *testing* untuk skenario 2 dan 4 cenderung sama. Hal ini juga terlihat pada Gambar 4.14 yang menunjukkan rata-rata RMSE data *testing* skenario 2 mendekati skenario 4.

#### 4.1.3 Peramalan dengan *Neural Network*

Pada metode *neural network*, terdapat berbagai kemungkinan jenis *input* dan banyaknya *neuron* yang digunakan. Dengan demikian, terdapat beberapa kemungkinan model yang terbentuk. Penentuan *input* dilakukan berdasarkan PACF dari  $Y_t$ . *Input* yang digunakan merupakan *lag* PACF dari data simulasi yang signifikan. PACF untuk seluruh data simulasi dapat dilihat pada Lampiran 2. Berdasarkan plot PACF data simulasi skenario 1 replikasi 1 ( $Y_{11}$ ), terdapat 4 kemungkinan *input*, yakni dengan menggunakan *lag* 1 saja, menggunakan *lag* 12 saja, menggunakan *lag* 1, 12 dan dengan menggunakan *lag* 1, 2, 11, 12, 13.

Selanjutnya dilakukan pengujian linieritas untuk seluruh kombinasi *input*. Pengujian linieritas dilakukan menggunakan uji terasvirta. Secara lengkap, pengujian untuk seluruh data simulasi dapat dilihat pada Lampiran 3. Hasil pengujian terasvirta untuk skenario 1 replikasi 1 dapat ditunjukkan pada Tabel 4.5.

**Tabel 4.5** Pengujian Linieritas Data Simulasi 1 Replikasi 1

<b>Lag input</b>	<b><math>\chi^2</math></b>	<b><i>p-value</i></b>	<b>Kesimpulan</b>
1	9,690	0,008	nonlinier
12	0,019	0,991	linier
1 dan 12	43,268	0,000	nonlinier
1, 2, 11, 12, dan 13	268,805	0,000	nonlinier

Tabel 4.5 menunjukkan bahwa dari 4 kombinasi *input* yang digunakan, terdapat 1 *input* yang memiliki hubungan linier dengan *output*, yakni penggunaan *input lag* 12. Namun demikian, *input* tersebut tetap dianalisis menggunakan *neural network* untuk

mengetahui perbandingan hasil akurasi antara *input* dan *output* yang memiliki hubungan linier dengan *input* dan *output* yang memiliki hubungan nonlinier.

Penentuan banyaknya *neuron* dilakukan dengan metode *cross validation* dengan banyaknya *neuron* adalah 1, 2, 3, 4, 5, 10, dan 15. Banyaknya *hidden layer* yang digunakan adalah 1 *hidden layer*, dengan fungsi aktivasi pada *hidden layer* berupa *tanh*, sedangkan fungsi aktivasi untuk *output layer* adalah *linear*. *Neuron* optimal yang terpilih adalah *neuron* yang menghasilkan tingkat kesalahan terkecil pada data *testing*. Tabel 4.6 menunjukkan hasil evaluasi model untuk data simulasi skenario 1 replikasi 1.

**Tabel 4.6** Pemilihan Model *Neural Network* Terbaik untuk Skenario 1  
Replikasi 1

Data	Lag <i>input</i>	<i>Neuron</i>	RMSE	MAE	MdAE	MdAPE	MAPE
Training	1	1	1,68	1,20	0,90	3,17	4,80
		2	1,27	0,89	0,61	2,29	4,13
		3	10,47	7,22	5,58	19,20	37,73
		4	1,05	0,76	0,54	1,87	2,85
		5	0,69	0,51	0,42	1,63	2,45
		10	0,70	0,51	0,43	1,75	2,16
		15	0,76	0,52	0,37	1,40	2,13
	12	1	14,61	10,90	7,78	26,94	43,87
		2	14,61	10,90	7,78	26,94	43,87
		3	1,63	1,19	0,90	3,23	4,30
		4	1,46	1,03	0,72	2,65	3,81
		5	0,78	0,56	0,41	1,67	2,14
		10	1,02	0,74	0,51	1,96	2,57
		15	0,92	0,62	0,40	1,36	2,27
	1 dan 12	1	14,61	10,90	7,78	26,94	43,87
		2	14,61	10,90	7,78	26,94	43,87
		3	4,43	2,78	1,47	4,61	14,02
		4	1,60	1,16	0,88	2,99	4,17
		5	0,87	0,63	0,37	1,73	2,56
		10	0,60	0,41	0,30	1,17	1,64
		15	<b>0,50</b>	<b>0,31</b>	<b>0,15</b>	<b>0,56</b>	<b>1,18</b>
	1, 2, 11, 12, dan 13	1	1,57	1,14	0,87	2,87	4,08
		2	1,49	1,06	0,79	2,58	3,75
		3	0,94	0,70	0,53	2,05	2,83
		4	1,34	0,92	0,67	2,26	3,25
		5	0,84	0,58	0,34	1,36	2,23
		10	0,88	0,60	0,40	1,58	2,39
		15	0,69	0,47	0,30	1,31	1,92

**Tabel 4.6** Pemilihan Model *Neural Network* Terbaik untuk Skenario 1 Replikasi 1 (*Lanjutan*)


Data	Lag input	Neuron	RMSE	MAE	MdAE	MdAPE	MAPE
<i>Testing</i>	1	1	4,03	2,03	<b>0,40</b>	<b>1,38</b>	4,14
		2	6,23	3,89	1,84	4,34	9,04
		3	12,56	10,57	12,23	25,99	24,75
		4	2,55	1,64	0,72	2,17	3,85
		5	7,69	4,18	2,31	5,96	10,02
		10	5,62	3,30	1,58	4,54	7,34
		15	5,80	4,67	3,04	9,94	11,00
	12	1	18,36	12,61	8,19	25,13	27,93
		2	18,36	12,61	8,19	25,13	27,93
		3	4,01	1,96	0,51	1,54	3,84
		4	3,52	1,81	0,68	1,86	<b>3,58</b>
		5	3,38	2,89	2,93	7,39	7,63
		10	2,32	1,58	0,88	2,35	3,86
		15	<b>1,99</b>	<b>1,55</b>	1,05	3,39	4,31
	1 dan 12	1	18,36	12,61	8,19	25,13	27,93
		2	18,36	12,61	8,19	25,13	27,93
		3	9,26	6,37	3,67	15,71	15,94
		4	4,00	1,93	0,60	1,82	3,83
		5	2,61	1,96	1,27	4,19	4,60
		10	3,77	3,16	2,81	6,18	9,43
		15	4,69	3,33	1,86	3,88	11,99
	1, 2, 11, 12, dan 13	1	4,01	1,95	0,50	1,84	3,84
		2	3,99	1,85	0,64	1,88	3,62
		3	6,99	3,69	1,32	3,57	7,77
		4	3,61	1,85	0,51	1,62	3,70
		5	3,16	1,87	1,18	2,68	4,57
		10	4,37	3,20	2,76	8,53	8,31
		15	3,54	2,08	1,25	3,43	4,80

Keterangan : angka yang dicetak tebal merupakan nilai minimum untuk setiap kriteria

Berdasarkan Tabel 4.6, terlihat bahwa untuk data *training*, model terbaik diperoleh dari model dengan *input*  $Y_{t-1}$  dan  $Y_{t-12}$ , dan memiliki 15 *neuron* berdasarkan kelima kriteria yang digunakan. Pemilihan model terbaik dilakukan berdasarkan kriteria data *testing*. Namun, berdasarkan data *testing*, terdapat perbedaan kesimpulan yang diperoleh untuk setiap kriteria. Dengan demikian, model terbaik yang dipilih merupakan model yang memiliki nilai minimum paling banyak di beberapa kriteria. Berdasarkan Tabel 4.6, dapat diketahui bahwa model dengan *input*  $Y_{t-1}$  dan memiliki 1 *neuron* merupakan model terbaik


berdasarkan kriteria MdAE dan MdAPE. Namun berdasarkan kriteria RMSE dan MAE, model dengan *input*  $Y_{t-12}$  dan memiliki 15 *neuron* merupakan model terbaik. Maka model terbaik yang dipilih adalah model yang memiliki arsitektur lebih sederhana, yakni model dengan *input*  $Y_{t-1}$  dan memiliki 1 *neuron*.

Kemudian dilakukan perbandingan *input* yang digunakan untuk keempat skenario dalam kriteria RMSE. Gambar 4.15 menunjukkan perbandingan hasil RMSE dari beberapa kemungkinan model *neural network* untuk penggunaan *input*.



**Gambar 4.15** Perbandingan RMSE dalam Pemilihan *Input* Model *Neural Network* untuk Data Simulasi.

Berdasarkan Gambar 4.15, terlihat bahwa untuk data *training*, RMSE minimum dihasilkan oleh model yang lebih kompleks, yakni model dengan 5 *input*. Sedangkan berdasarkan rata-rata RMSE data *testing*, *input* optimal untuk skenario 2 dan 3 adalah *lag* 1, 2, 11, 12, dan 13. Sedangkan untuk skenario ke 1 dan 4, *input* optimalnya adalah *lag* 12. *Input lag* 1 dan 12 menghasilkan RMSE yang cenderung besar, baik untuk data *training* maupun data *testing*. RMSE untuk data *training* cenderung lebih kecil dibandingkan RMSE data *testing* pada seluruh jenis kombinasi *input*. Selanjutnya dilakukan perbandingan penggunaan kombinasi *neuron* untuk pembentukan model *neural network* pada setiap skenario dan replikasi, yang dapat ditunjukkan pada Gambar 4.16.



**Gambar 4.16** Perbandingan RMSE dalam Pemilihan *Neuron Model Neural Network* untuk Data Simulasi.

Berdasarkan Gambar 4.16, dapat diketahui bahwa untuk data *training*, penambahan jumlah *neuron* akan menghasilkan RMSE yang cenderung lebih kecil sehingga akurasi akan lebih baik. Rata-rata RMSE terkecil dihasilkan oleh *neuron* 15 untuk seluruh skenario. Penggunaan 1 hingga 3 *neuron* akan menghasilkan RMSE yang cenderung besar, sedangkan penggunaan *neuron* lebih dari 4 menghasilkan RMSE yang cenderung kecil.


Berdasarkan RMSE data *testing*, penambahan jumlah *neuron* tidak selalu meningkatkan akurasi. *Neuron* optimal yang menghasilkan rata-rata RMSE terkecil untuk skenario 1 adalah sebanyak 5, untuk skenario 2, 3, dan 4 sebanyak 4 *neuron* saja. Penentuan *neuron* optimal dilakukan berdasarkan RMSE pada data *testing*. Dengan demikian, diperlukan *trial and error* dalam menentukan *neuron* optimal pada model *neural network* karena penambahan jumlah *neuron* tidak selalu meningkatkan akurasi. Langkah yang sama juga dilakukan untuk replikasi lainnya pada seluruh skenario yang digunakan. Setelah diperoleh nilai tingkat kesalahan peramalan untuk setiap kemungkinan model, maka model *neural network* terbaik untuk setiap skenario dan replikasi dapat ditunjukkan oleh Tabel 4.7.



**Tabel 4.7** *Input dan Neuron Optimal Model Neural Network untuk Data Simulasi.*

Data simulasi	Input optimal	Neuron optimal
Y <sub>_11</sub>	$Y_{t-1}$	1
Y <sub>_12</sub>	$Y_{t-12}$	4
Y <sub>_13</sub>	$Y_{t-12}$	1
Y <sub>_14</sub>	$Y_{t-12}$	2
Y <sub>_15</sub>	$Y_{t-12}$	1
Y <sub>_21</sub>	$Y_{t-1}, Y_{t-2}, Y_{t-11}, Y_{t-12}, \text{ dan } Y_{t-13}$	3
Y <sub>_22</sub>	$Y_{t-1}$	4
Y <sub>_23</sub>	$Y_{t-1}$	10
Y <sub>_24</sub>	$Y_{t-1}$	4
Y <sub>_25</sub>	$Y_{t-1}$	4
Y <sub>_31</sub>	$Y_{t-1}, Y_{t-2}, Y_{t-11}, Y_{t-12}, \text{ dan } Y_{t-13}$	10
Y <sub>_32</sub>	$Y_{t-12}$	4
Y <sub>_33</sub>	$Y_{t-12}$	2
Y <sub>_34</sub>	$Y_{t-12}$	2
Y <sub>_35</sub>	$Y_{t-1}$	4
Y <sub>_41</sub>	$Y_{t-12}$	3
Y <sub>_42</sub>	$Y_{t-1}, Y_{t-2}, Y_{t-11}, Y_{t-12}, \text{ dan } Y_{t-13}$	4
Y <sub>_43</sub>	$Y_{t-12}$	2
Y <sub>_44</sub>	$Y_{t-1}, Y_{t-2}, Y_{t-11}, Y_{t-12}, \text{ dan } Y_{t-13}$	1
Y <sub>_45</sub>	$Y_{t-1}, Y_{t-2}, Y_{t-11}, Y_{t-12}, \text{ dan } Y_{t-13}$	2

Tabel 4.7 menunjukkan bahwa model *neural network* terbaik untuk setiap skenario dan replikasinya dihasilkan oleh kombinasi *input* dan *neuron* yang berbeda. Bahkan, terdapat data simulasi yang *input* optimalnya dihasilkan oleh *input* yang memiliki hubungan linier dengan *output*, yakni pada data simulasi yang memiliki *input* optimal berupa *lag* 12 saja. Pada skenario 4, *input* optimal yang terpilih cenderung merupakan *input* yang lebih kompleks, yakni penggunaan *input* sebanyak 5 *input*. Sedangkan untuk skenario 1 *input* optimal yang terpilih adalah sebanyak satu *input* untuk seluruh replikasi. Setelah diperoleh model terbaik untuk setiap data simulasi, maka dilakukan perbandingan performa *neural network* dalam memodelkan keempat skenario pada data simulasi. Gambar 4.17 menunjukkan perbandingan data aktual dan ramalan untuk data *testing* pada replikasi 1 di setiap skenario.




**Gambar 4.17** Perbandingan Data Aktual dan Ramalan Model *Neural Network* untuk Simulasi Replikasi Pertama pada Skenario 1 (a), Skenario 2 (b), Skenario 3 (c), dan Skenario 4 (d).

Gambar 4.17, menunjukkan bahwa model *neural network* dapat menangkap pola data aktual dengan baik untuk semua skenario pada replikasi 1. Perbandingan performa model *neural network* untuk setiap skenario berdasarkan kriteria RMSE, MAE, MdAE, dan MAPE dapat ditunjukkan pada Tabel 4.8.

**Tabel 4.8** Perbandingan Kriteria RMSE, MAE, MdAE, MdAPE, dan MAPE Model *Neural Network* untuk Data Simulasi


Data	Training					Testing				
	RMSE	MAE	MdAE	MdAPE	MAPE	RMSE	MAE	MdAE	MdAPE	MAPE
Y_11	1,68	1,20	0,90	3,17	4,80	4,03	2,04	0,40	1,38	4,15
Y_12	1,12	0,79	0,58	2,19	3,16	1,36	1,11	0,78	2,16	3,59
Y_13	1,22	0,98	0,88	2,98	3,76	1,68	1,35	1,45	4,67	3,69
Y_14	1,22	0,93	0,76	2,48	3,64	1,62	1,22	0,62	2,09	3,53
Y_15	1,32	1,04	0,83	3,05	4,03	1,74	1,39	1,03	2,79	3,70
Y_21	3,36	2,52	2,02	7,21	9,66	3,99	2,96	2,01	5,86	7,58
Y_22	3,43	2,47	1,83	7,20	9,15	4,44	3,43	2,88	4,82	8,36
Y_23	3,19	2,31	1,70	6,27	8,70	4,37	3,48	3,33	7,02	8,86
Y_24	3,28	2,27	1,42	5,49	8,57	4,02	3,19	3,09	6,85	7,82
Y_25	3,16	2,29	1,77	7,18	8,81	4,35	3,45	2,89	7,51	8,91
Y_31	1,88	1,19	0,66	2,10	4,36	2,93	2,25	1,82	4,52	6,46
Y_32	2,62	1,86	1,39	4,43	7,99	3,12	2,66	2,54	6,28	7,88
Y_33	3,08	2,53	2,16	6,72	10,98	3,14	2,62	2,63	7,71	7,23
Y_34	3,02	2,41	1,98	6,34	10,28	3,87	3,16	3,14	7,53	8,80
Y_35	2,74	1,96	1,53	4,77	3,11	8,04	2,57	2,38	4,87	6,99
Y_41	4,23	3,46	3,13	10,36	14,40	4,27	3,71	3,13	9,67	9,91
Y_42	4,05	3,03	2,48	8,33	11,73	7,51	5,35	3,36	9,12	11,51
Y_43	4,29	3,44	3,07	10,88	14,26	4,90	4,35	3,74	9,67	10,91
Y_44	4,13	3,27	2,83	10,27	13,31	5,09	4,52	3,92	8,33	11,21
Y_45	4,04	3,14	2,81	9,40	13,26	4,97	4,33	3,72	10,14	10,39

Untuk memudahkan dalam melakukan perbandingan, informasi pada Tabel 4.8 dapat diilustrasikan kedalam Gambar 4.18.




**Gambar 4.18** Perbandingan Kriteria Model *Neural Network* Data Simulasi.

Berdasarkan Gambar 4.18, dapat diketahui bahwa nilai MAE dan MdAE untuk keempat skenario cenderung sama. Hal ini menunjukkan bahwa data residual model *neural network* memiliki pola yang simetris, sehingga penggunaan kriteria berbasis *mean* maupun *median* dapat digunakan untuk mengevaluasi kebaikan model. Untuk membandingkan kemampuan model *neural network* dalam menangkap pola heterogenitas musiman dan pola nonlinieritas, maka dilakukan perbandingan untuk setiap skenario dan replikasi pada data *training* maupun *testing* menggunakan kriteria RMSE seperti pada Gambar 4.19.



**Gambar 4.19** Perbandingan RMSE Model *Neural Network* untuk Data Simulasi.

Berdasarkan Gambar 4.19, dapat diketahui bahwa untuk data *training*, skenario 1 memiliki nilai RMSE yang paling rendah, diikuti oleh skenario 3, skenario 2, dan skenario 4. Hal ini berlaku untuk seluruh replikasi. Namun RMSE untuk data *testing* menunjukkan bahwa pada replikasi tertentu, skenario 1 tidak selalu memiliki RMSE terkecil, begitu pula skenario yang lain. RMSE data *training* untuk seluruh replikasi cenderung tidak berbeda jauh. Namun pada data *testing* terdapat beberapa replikasi yang memiliki nilai RMSE lebih tinggi dibandingkan replikasi lainnya. Untuk memudahkan dalam membandingkan RMSE data *testing* tiap-tiap skenario maka dilakukan perhitungan rata-rata dari seluruh replikasi sehingga diperoleh Gambar 4.20.




**Gambar 4.20** Perbandingan RMSE *Training-Testing* Model *Neural Network* untuk Data Simulasi.

Berdasarkan Gambar 4.20, dapat diketahui bahwa untuk skenario 1 dan 2, nilai RMSE data *training* dan data *testing* tidak terpaut jauh. Sedangkan untuk data yang memiliki pola nonlinieritas pada residualnya memiliki selisih rata-rata RMSE yang cenderung berbeda untuk data *training* dan *testing*nya. Untuk semua skenario, nilai RMSE data *testing* lebih besar dibandingkan data *training*. Nilai RMSE data *testing* yang lebih tinggi dibandingkan dengan data *training* menunjukkan bahwa akurasi model *neural network* untuk data *testing* lebih rendah dibandingkan akurasi pada data *training*. Hal ini sesuai dengan analisis yang telah dilakukan oleh Faraway dan Chatfield (1998) yang menyatakan bahwa model *neural network* yang dapat menangkap pola data *training* dengan baik juga dapat menghasilkan peramalan yang kurang baik untuk data *testing*nya.

#### 4.1.4 Peramalan dengan *Hybrid Quantile Regression Neural Network*

Estimasi parameter untuk setiap kuantil dilakukan secara independen yang dapat mengakibatkan terjadinya *crossing* antar kuantil. Hal ini akan menyebabkan adanya ketidaksesuaian dengan karakteristik cdf yang merupakan fungsi monoton naik (Cannon, 2011). Pada penelitian ini, digunakan beberapa jenis *input*. *Input* terbaik yang dipilih adalah *input* yang memiliki


jumlah *crossing* paling sedikit dengan akurasi peramalan titik terbaik. Dengan demikian, dilakukan pemodelan QRNN dengan 6 jenis kombinasi, seperti langkah analisis pada bab 3. Gambar 4.21 menunjukkan perbandingan *crossing* yang dihasilkan.



**Gambar 4.21** Perbandingan *Crossing* yang Model QRNN untuk Data Simulasi pada Data *Training* (a) dan *Testing* (b).

Pada data simulasi, model QRNN keempat (penggunaan *input* berupa prediksi *neural network* dan *lag*  $Y_t$  dari PACF residual model *neural network*) tidak digunakan karena hanya terdapat 4 dari 20 data simulasi yang memiliki residual model *neural network* belum *white noise*. Berdasarkan Gambar 4.21, dapat diketahui bahwa pemodelan QRNN secara langsung (satu tahap) akan mengakibatkan banyak terjadinya *crossing* antar kuantilnya. Semakin banyak *neuron* yang digunakan, banyaknya *crossing* yang terjadi juga cenderung semakin banyak. Hal ini berlaku untuk 20 replikasi yang digunakan. Dengan menggunakan *input* berupa nilai prediksi *time series regression* dan *lag* residual maupun *lag*  $Y_t$ , *crossing* yang dihasilkan cenderung lebih sedikit. Namun demikian, pemodelan dengan menggunakan nilai prediksi *neural network* dan juga melalui proses dekomposisi akan menghasilkan *crossing* yang paling sedikit.

Pada pemodelan QRNN menggunakan *input* berupa prediksi *neural network* dan *input* berupa *lag* residual dari proses dekomposisi hanya digunakan *input* sebanyak satu. Sedangkan pada pemodelan QRNN satu tahap, *input* yang digunakan adalah 21 variabel *dummy* dan *lag*  $Y_t$ . Dengan demikian, pemodelan menggunakan *input* yang lebih banyak akan meningkatkan kemungkinan terjadinya *crossing* antar kuantilnya. Hal ini sesuai dengan studi sebelumnya yang menyatakan bahwa jumlah prediktor yang semakin banyak akan semakin menimbulkan permasalahan *crossing* karena kurva model QRNN akan memiliki ruang yang lebih luas untuk menimbulkan *crossing* (Bondell, Reich, & Wang, 2010). Untuk menentukan model QRNN yang akan digunakan, akan dilakukan perbandingan secara keseluruhan berdasarkan rata-rata *crossing* dari 20 data simulasi yang tersedia, yang ditunjukkan oleh Gambar 4.22.




**Gambar 4.22** Perbandingan Rata-rata *Crossing* Model QRNN untuk Data Simulasi

Gambar 4.22 menunjukkan bahwa untuk data *training*, banyaknya *crossing* pada QRNN dengan dekomposisi cenderung sama dengan QRNN menggunakan *input neural network*. Namun berdasarkan data *testing*, model QRNN yang memiliki rata-rata *crossing* paling sedikit adalah model QRNN dengan dekomposisi. Namun, penggunaan dekomposisi juga masih menghasilkan adanya *crossing* pada beberapa kuantil. Dengan demikian, hasil peramalan interval yang diperoleh akan menjadi tidak *valid*, karena terdapat kemungkinan bahwa nilai batas atas akan lebih kecil dibandingkan batas bawahnya. Berdasarkan hal tersebut, pada data simulasi, perbandingan kebaikan peramalan interval tidak dapat dilakukan. Kemudian akan dilakukan perbandingan tingkat kesalahan yang dihasilkan oleh kelima model QRNN. Gambar 4.23 menunjukkan perbandingan RMSE untuk penggunaan model QRNN dan banyaknya *neuron* yang digunakan.


Gambar 4.23 menunjukkan bahwa pada data *training*, pemodelan QRNN satu tahap akan menghasilkan RMSE yang lebih kecil, seiring dengan penambahan *neuron* yang digunakan. Namun pada data *testing*, terdapat satu data yang memiliki RMSE jauh dibandingkan yang lain. Hal ini dapat disebabkan oleh tingginya nilai prediksi pada pengamatan tertentu yang mengakibatkan nilai RMSE akan sangat besar. Dengan demikian, pemilihan jenis model QRNN yang digunakan adalah melalui kriteria yang berbasis median.





**Gambar 4.23** Perbandingan RMSE dan Banyaknya *Neuron* Model QRNN Data Simulasi untuk *Training* (a) dan *Testing* (b).

Selanjutnya, Gambar 4.24 menunjukkan perbandingan MdAE dan MdAPE untuk data *training* dan *testing*.



**Gambar 4.24** Perbandingan MdAE dan MdAPE Model QRNN untuk Data Simulasi.

Seperti halnya nilai RMSE, penggunaan MdAE dan MdAPE juga menunjukkan bahwa model QRNN satu tahap akan menghasilkan tingkat kesalahan yang kecil pada data *training* dengan bertambahnya jumlah *neuron*. Namun pada data *testing*, penambahan *neuron* cenderung akan meningkatkan tingkat kesalahan. Sedangkan untuk model QRNN dengan *input neural network* dan QRNN dengan dekomposisi menunjukkan bahwa tingkat kesalahan kedua jenis model QRNN tidak berbeda signifikan. Nilai rata-rata MdAPE data *testing* pada model QRNN dengan dekomposisi sedikit lebih rendah dibandingkan dengan QRNN dengan *input neural network*.

Berdasarkan uraian sebelumnya, diperoleh bahwa model QRNN dengan dekomposisi memiliki jumlah *crossing* yang lebih sedikit. Dengan demikian, pemodelan QRNN untuk data simulasi dilakukan dengan menggunakan dekomposisi sebagai *preprocessing*, banyaknya *hidden layer* adalah 1, *input* yang digunakan adalah *lag* residual dari proses dekomposisi yang signifikan dan *output* nya adalah nilai residual.

Selanjutnya, dilakukan pemodelan QRNN untuk seluruh data simulasi. Sebelum dilakukan pemodelan, akan dilakukan pengujian linieritas pada *input* yang digunakan. Untuk skenario 1 replikasi 1, diperoleh nilai  $\chi^2$  sebesar 0,600 dengan *p-value* sebesar 0,740. Dengan hipotesis awal adalah hubungan antara *input* dan *output* bersifat linier, maka hipotesis awal gagal ditolak. Dengan demikian, *input* yang digunakan memiliki hubungan linier dengan *output*.

Banyaknya *neuron* optimal ditentukan melalui proses *cross validation*. Dengan menggunakan *cross validation*, *neuron* yang terpilih adalah *neuron* yang menghasilkan model dengan akurasi terbaik pada data *testing*. Kriteria akurasi yang digunakan adalah kriteria RMSE, MAE, MdAE, MdAPE, dan MAPE. Secara lengkap, nilai kriteria untuk seluruh data simulasi dapat dilihat pada Lampiran 4. Tabel 4.9 menunjukkan nilai kriteria untuk data simulasi skenario 1 replikasi 1.

**Tabel 4.9** Pemilihan *Neuron* Optimal Model *Quantile Regression Neural Network* untuk Data Simulasi Skenario 1 Replikasi 1

<i>Neuron</i>	<i>Training</i>					<i>Testing</i>				
	RMSE	MAE	MdAE	MdAPE	MAPE	RMSE	MAE	MdAE	MdAPE	MAPE
1	0,91	0,71	0,58	1,86	2,89	<b>2,20</b>	<b>1,51</b>	<b>0,91</b>	<b>2,80</b>	<b>3,79</b>
2	0,90	0,70	0,59	1,90	2,88	2,64	1,97	1,50	4,88	5,26
3	0,90	0,70	0,59	1,90	2,88	2,63	1,96	1,49	4,83	5,23
4	0,88	0,67	0,57	1,93	2,91	2,67	2,02	1,49	4,93	5,42
5	0,90	0,69	0,59	2,01	2,93	2,62	1,94	1,43	4,73	5,20
10	0,88	0,66	0,51	1,71	2,75	2,64	1,98	1,46	4,80	5,32
15	0,83	0,60	0,45	1,70	2,45	2,68	2,02	1,42	4,70	5,42

Keterangan : angka yang dicetak tebal merupakan nilai minimum untuk setiap kriteria

Berdasarkan Tabel 4.9, dapat diketahui bahwa kelima jenis kriteria yang digunakan menunjukkan kesimpulan yang sama. *Neuron* optimal untuk data simulasi skenario 1 replikasi 1 adalah sebanyak 1 *neuron*. Dengan cara yang sama, dilakukan pemilihan banyaknya *neuron* pada keempat skenario dan kelima replikasi yang ada sehingga diperoleh *neuron* optimal untuk setiap data simulasi.


Kemudian, untuk mengetahui performansi model *quantile regression neural network* dalam menangkap pola keempat

skenario, dilakukan perhitungan nilai RMSE, MAE, MdAE, MdAPE, dan MAPE untuk setiap data simulasi. Tabel 4.10 menunjukkan kriteria model *quantile regression neural network*.

**Tabel 4.10** Perbandingan Kriteria Model *Quantile Regression Neural Network* untuk Data Simulasi


Data	Simulasi	Neuron	RMSE	MAE	MdAE	MdAPE	MAPE
Training	Y_11	1	0,91	0,71	0,58	1,86	2,89
	Y_12	4	1,23	0,95	0,78	2,55	3,85
	Y_13	3	1,15	0,91	0,78	2,78	3,63
	Y_14	4	1,17	0,88	0,63	2,32	3,59
	Y_15	10	1,27	0,96	0,75	2,55	4,01
	Y_21	1	3,57	2,84	2,31	9,62	11,67
	Y_22	10	3,55	2,62	1,88	7,44	10,68
	Y_23	15	3,32	2,45	1,98	6,23	9,33
	Y_24	4	3,44	2,53	1,87	6,72	10,32
	Y_25	3	3,50	2,72	2,34	9,36	11,23
	Y_31	4	2,66	1,96	1,65	4,79	9,02
	Y_32	10	2,94	2,21	1,69	5,00	11,01
	Y_33	1	2,94	2,31	2,01	6,60	11,07
	Y_34	1	2,90	2,30	1,79	6,85	10,39
	Y_35	1	3,10	2,44	1,96	6,85	12,45
	Y_41	10	4,13	3,11	2,73	10,45	13,11
	Y_42	15	4,07	2,98	2,32	8,33	12,80
	Y_43	5	4,30	3,28	2,54	9,38	14,47
	Y_44	5	4,24	3,11	2,19	8,35	12,64
	Y_45	3	4,30	3,42	3,05	10,64	15,09
Testing	Y_11	1	2,20	1,51	0,91	2,80	3,79
	Y_12	4	1,54	1,13	0,67	1,61	3,69
	Y_13	3	1,60	1,25	1,22	3,42	3,55
	Y_14	4	1,57	1,21	0,65	2,02	3,51
	Y_15	10	1,70	1,28	1,03	2,40	3,50
	Y_21	1	4,30	3,31	2,79	6,49	7,92
	Y_22	10	3,58	2,83	2,36	6,71	7,04
	Y_23	15	4,11	3,06	2,04	6,17	7,93
	Y_24	4	3,80	2,81	3,07	7,14	6,97
	Y_25	3	4,19	3,04	1,82	5,51	8,04
	Y_31	4	4,20	3,08	1,96	6,20	8,63
	Y_32	10	3,15	2,64	2,34	7,86	8,40
	Y_33	1	3,18	2,75	2,40	7,05	8,16
	Y_34	1	3,83	3,43	3,47	9,46	9,95
	Y_35	1	3,16	2,49	2,37	6,38	6,85
	Y_41	10	4,02	3,47	3,55	9,47	9,19
	Y_42	15	4,12	3,30	2,72	6,41	9,69
	Y_43	5	4,03	3,39	2,87	6,74	9,35
	Y_44	5	4,23	3,50	3,62	10,16	9,87
	Y_45	3	4,00	3,32	2,58	8,63	8,83

Nilai kriteria kebaikan model pada Tabel 4.10 dapat diilustrasikan kedalam Gambar 4.25.



**Gambar 4.25** Perbandingan Kriteria Model *Quantile Regression Neural Network* untuk Data Simulasi.


Gambar 4.25 menunjukkan bahwa skenario yang memiliki rata-rata kesalahan terkecil adalah skenario 1 dan skenario yang memiliki kesalahan peramalan terbesar adalah skenario 4. Hasil tersebut konsisten dengan model ARIMAX dan *neural network*. Dengan demikian adanya pola nonlinieritas dan heteroskedastisitas mengakibatkan pola data aktual lebih sulit diidentifikasi. Untuk mengetahui konsistensi setiap replikasi yang digunakan, Gambar 4.26 menunjukkan nilai RMSE setiap data simulasi.



**Gambar 4.26** Perbandingan Kriteria Model *Quantile Regression Neural Network* untuk Data Simulasi Setiap Replikasi.

Gambar 4.26 menunjukkan bahwa pada data *training*, model QRNN pada kelima replikasi untuk seluruh skenario cenderung menghasilkan tingkat kesalahan yang sama. Pada data *testing*, skenario 2, 3, dan 4 menghasilkan variasi kesalahan yang

lebih besar dibandingkan skenario 1. Kemudian dilakukan perbandingan data aktual dan ramalan seperti pada Gambar 4.27.



**Gambar 4.27** Perbandingan Data Aktual dan Ramalan Model QRNN pada Skenario 1 (a), Skenario 2 (b), Skenario 3 (c), dan Skenario 4 (d).

Gambar 4.27 menunjukkan bahwa model *quantile regression neural network* dapat mengikuti pola data aktual, baik untuk data *training* maupun data *testing*. Hasil peramalan interval menunjukkan bahwa heteroskedastisitas akan mengakibatkan peramalan interval menjadi lebih lebar, yakni pada skenario 2 dan skenario 4. Sedangkan pada skenario 1 dan 3, peramalan interval yang terbentuk cenderung lebih sempit. Namun demikian, masih terdapat beberapa *crossing* pada beberapa data simulasi. Hal ini mengakibatkan peramalan interval kurang *valid* sehingga tidak dapat dilakukan perbandingan peramalan interval metode *quantile regression neural network* dengan metode lainnya.

#### 4.1.5 Perbandingan model ARIMAX, Neural Network, dan Quantile Regression Neural Network data Simulasi

Setelah diperoleh model terbaik untuk setiap metode, maka akan dilakukan perbandingan ketiga metode untuk menentukan menentukan metode terbaik dalam meramalkan data simulasi. Tabel 4.11 menunjukkan kriteria yang digunakan untuk membandingkan ketiga metode berdasarkan tingkat kesalahan peramalan pada data *testing*nya.

**Tabel 4.11** Perbandingan Model ARIMAX, Neural Network, dan *Quantile Regression Neural Network* untuk Data Simulasi

Data	Metode	RMSE	MAE	MdAE	MdAPE	MAPE
Y_11	ARIMAX	2,25	1,55	0,98	3,14	3,98
	NN	4,03	2,03	0,40	1,38	4,14
	<b>QRNN</b>	<b>2,20</b>	<b>1,51</b>	<b>0,91</b>	<b>2,80</b>	<b>3,79</b>
Y_12	ARIMAX	1,66	1,12	<b>0,43</b>	<b>1,07</b>	3,81
	NN	<b>1,36</b>	<b>1,11</b>	0,78	2,16	<b>3,59</b>
	QRNN	1,54	1,13	0,67	1,61	3,69
Y_13	ARIMAX	1,70	1,38	1,38	3,76	3,97
	NN	1,68	1,35	1,45	4,67	3,69
	<b>QRNN</b>	<b>1,60</b>	<b>1,25</b>	<b>1,22</b>	<b>3,42</b>	<b>3,55</b>
Y_14	ARIMAX	1,64	1,25	0,73	<b>1,89</b>	3,61
	NN	1,62	1,22	<b>0,62</b>	2,09	3,53
	<b>QRNN</b>	<b>1,57</b>	<b>1,21</b>	0,65	2,02	<b>3,51</b>
Y_15	ARIMAX	1,83	1,41	1,14	2,92	3,87
	NN	1,74	1,39	1,03	2,79	3,70
	<b>QRNN</b>	<b>1,70</b>	<b>1,28</b>	<b>1,03</b>	<b>2,40</b>	<b>3,50</b>

**Tabel 4.11** Perbandingan Model ARIMAX, *neural network*, dan *Quantile Regression Neural Network* untuk Data Simulasi (*Lanjutan*)

Data	Metode	RMSE	MAE	MdAE	MdAPE	MAPE
Y_21	ARIMAX	4,38	3,35	2,64	6,33	7,87
	NN	<b>3,99</b>	<b>2,96</b>	<b>2,01</b>	<b>5,86</b>	<b>7,58</b>
	QRNN	4,30	3,31	2,79	6,49	7,92
Y_22	ARIMAX	4,62	3,51	2,72	6,61	8,69
	NN	4,44	3,43	2,88	<b>4,82</b>	8,36
	QRNN	<b>3,58</b>	<b>2,83</b>	<b>2,36</b>	6,71	<b>7,04</b>
Y_23	ARIMAX	4,18	3,45	3,12	7,96	8,70
	NN	4,37	3,48	3,32	7,02	8,86
	QRNN	<b>4,11</b>	<b>3,06</b>	<b>2,04</b>	<b>6,17</b>	<b>7,93</b>
Y_24	ARIMAX	3,97	2,92	<b>2,81</b>	6,89	7,08
	NN	4,02	3,19	3,09	<b>6,85</b>	7,82
	QRNN	<b>3,80</b>	<b>2,81</b>	3,07	7,14	<b>6,97</b>
Y_25	ARIMAX	4,32	3,30	2,20	6,42	8,48
	NN	4,35	3,45	2,89	7,51	8,91
	QRNN	<b>4,19</b>	<b>3,04</b>	<b>1,82</b>	<b>5,51</b>	<b>8,04</b>
Y_31	ARIMAX	3,18	2,55	2,65	4,79	7,08
	NN	<b>2,93</b>	<b>2,25</b>	<b>1,82</b>	<b>4,52</b>	<b>6,46</b>
	QRNN	4,20	3,08	1,96	6,20	8,63
Y_32	ARIMAX	<b>3,06</b>	<b>2,59</b>	2,40	8,20	8,20
	NN	3,12	2,66	2,54	<b>6,28</b>	<b>7,88</b>
	QRNN	3,15	2,64	<b>2,34</b>	7,86	8,40
Y_33	<b>ARIMAX</b>	<b>3,00</b>	<b>2,57</b>	<b>2,35</b>	7,57	7,43
	NN	3,14	2,62	2,63	7,71	<b>7,23</b>
	QRNN	3,18	2,75	2,40	<b>7,05</b>	8,16
Y_34	<b>ARIMAX</b>	<b>3,75</b>	<b>3,13</b>	<b>3,02</b>	8,35	9,07
	NN	3,87	3,16	3,14	<b>7,53</b>	<b>8,80</b>
	QRNN	3,83	3,43	3,47	9,46	9,95
Y_35	ARIMAX	<b>3,05</b>	2,51	2,55	6,46	6,89
	NN	8,04	2,57	2,38	<b>4,87</b>	6,99
	QRNN	3,16	<b>2,49</b>	<b>2,37</b>	6,38	<b>6,85</b>
Y_41	ARIMAX	4,20	3,71	3,22	10,11	9,80
	NN	4,27	3,71	<b>3,13</b>	9,66	9,91
	QRNN	<b>4,02</b>	<b>3,47</b>	3,55	<b>9,47</b>	<b>9,19</b>
Y_42	ARIMAX	4,45	3,81	3,44	10,84	10,13
	NN	7,51	5,35	3,36	9,12	11,51
	QRNN	<b>4,12</b>	<b>3,30</b>	<b>2,72</b>	<b>6,41</b>	<b>9,69</b>




**Tabel 4.11** Perbandingan Model ARIMAX, *neural network*, dan *Quantile Regression Neural Network* untuk Data Simulasi (Lanjutan)

Data	Metode	RMSE	MAE	MdAE	MdAPE	MAPE
Y_43	ARIMAX	4,29	3,73	2,91	8,31	9,90
	NN	4,90	4,35	3,74	9,67	10,91
	<b>QRNN</b>	<b>4,03</b>	<b>3,39</b>	<b>2,87</b>	<b>6,74</b>	<b>9,35</b>
Y_44	ARIMAX	4,62	3,98	4,11	10,91	10,54
	NN	5,09	4,52	3,92	<b>8,33</b>	11,21
	<b>QRNN</b>	<b>4,23</b>	<b>3,50</b>	<b>3,62</b>	10,16	<b>9,87</b>
Y_45	ARIMAX	4,37	3,74	3,36	9,35	9,65
	NN	4,97	4,33	3,72	10,14	10,39
	<b>QRNN</b>	<b>4,00</b>	<b>3,32</b>	<b>2,58</b>	<b>8,63</b>	<b>8,83</b>

Keterangan : angka yang dicetak tebal merupakan nilai minimum untuk setiap kriteria pada setiap data.


Tabel 4.11 menunjukkan bahwa metode terbaik untuk setiap data simulasi dapat berbeda dalam setiap replikasinya. Untuk mengetahui kemampuan setiap metode dalam mengatasi permasalahan heteroskedastisitas dan nonlinieritas, akan dilakukan perbandingan rata-rata MdAE untuk setiap skenario, seperti ditunjukkan pada Gambar 4.28.




**Gambar 4.28** Perbandingan Model ARIMAX, *Neural Network*, dan *Quantile Regression Neural Network* untuk Data Simulasi

Gambar 4.28 menunjukkan bahwa pada skenario 1 dan 3, ketiga metode menghasilkan tingkat kesalahan yang cenderung sama untuk data *testing*. Sedangkan untuk data simulasi yang mengandung heteroskedastisitas pada pola musiman, metode QRNN merupakan metode terbaik, yang ditunjukkan oleh MdAE

terkecil pada skenario 2 dan 4. Perbandingan pola residual linier dan nonlinier berdasarkan musiman yang homogen dapat ditunjukkan pada Gambar 4.29. Sedangkan perbandingan pola musiman yang homogen berdasarkan residual linier dan nonlinier dapat ditunjukkan pada Gambar 4.30.



**Gambar 4.29** Perbandingan Pola Residual Linier dan Nonlinier Berdasarkan Musiman yang Homogen




**Gambar 4.30** Perbandingan Pola Musiman yang Homogen Berdasarkan Residual Linier dan Nonlinier

Berdasarkan Gambar 4.29 dan Gambar 4.30 dapat diketahui bahwa ketiga metode cenderung memiliki MdAE yang sama pada data yang mengandung pola musiman homogen baik untuk residual linier maupun nonlinier. Ketiga metode yang digunakan cenderung memiliki performa yang berbeda apabila terdapat permasalahan heteroskedastisitas. Dengan demikian, pola nonlinieritas cenderung tidak membedakan performa ketiga metode. Hal ini dapat disebabkan oleh penggunaan pola tersebut hanya pada noise, sehingga nilainya cenderung kecil apabila

dibandingkan dengan pola heteroskedastisitas yang terjadi pada komponen musiman.

Secara keseluruhan, metode QRNN merupakan metode terbaik untuk 14 data simulasi, metode ARIMAX terbaik pada 3 data simulasi dan metode *neural network* terbaik pada 3 data simulasi. Untuk mengetahui perbandingan pada tiap skenario, Tabel 4.11 dapat diilustrasikan kedalam Gambar 4.31.




**Gambar 4.31** Metode Terbaik Tiap Skenario dan Simulasi.

Gambar 4.31 menunjukkan bahwa untuk skenario 1, model *neural network* merupakan model terbaik dalam 1 replikasi, sedangkan untuk 4 replikasi lainnya, model terbaik dihasilkan oleh QRNN. Pada skenario 2, model *neural network* terbaik untuk 1 replikasi dan QRNN untuk 4 replikasi lainnya. Pada skenario 3, ketiga metode menghasilkan peramalan terbaik pada beberapa replikasi. Sedangkan pada skenario 4, seluruh replikasi menunjukkan bahwa metode QRNN merupakan metode terbaik untuk meramalkan skenario 4. Hal ini dapat disebabkan pada skenario 4 terdapat heteroskedastisitas pada pola musiman, dan *noise* yang berpola nonlinier. Dengan demikian, metode QRNN mampu menangkap permasalahan heteroskedastisitas dan nonlinieritas, sesuai dengan karakteristik metode regresi kuantil yang dapat menangkap heteroskedastisitas dan juga *neural network* yang dapat menangkap pola nonlinieritas.

## 4.2 Karakteristik Data *Inflow* dan *Outflow* di Indonesia


Aplikasi metode QRNN pada data *inflow* dan *outflow* di Indonesia didasarkan pada karakteristik data *inflow* dan *outflow* yang mengandung heteroskedastisitas pada musiman dan juga nonlinieritas. Sebelum dilakukan peramalan data *inflow* dan *outflow*, akan dilakukan analisis statistika deskriptif untuk mengetahui gambaran karakteristik data *inflow* dan *outflow*. Gambar 4.32 menunjukkan perkembangan jumlah *inflow* dan *outflow* di Indonesia setiap tahunnya.




**Gambar 4.32** Perkembangan Jumlah *Inflow* dan *Outflow* di Indonesia.

Gambar 4.32 menunjukkan bahwa setiap tahunnya, jumlah *outflow* lebih tinggi dibandingkan jumlah *inflow*. Hal ini dapat disebabkan oleh adanya inflasi dan pertumbuhan ekonomi sehingga uang yang dikeluarkan oleh Bank Indonesia akan lebih besar dibandingkan dengan uang yang masuk ke Bank Indonesia. Pada data *inflow* dan *outflow*, terjadi peningkatan pada tahun 2003 hingga 2006, kemudian menurun hingga 2008 dan meningkat kembali hingga 2016. Hal ini dapat disebabkan oleh kebijakan Bank Indonesia terkait peredaran uang. Pada penelitian ini, analisis dilakukan untuk setiap pecahan. *Time series plot* pada Gambar 4.33 dan Gambar 4.34 menunjukkan bahwa kebijakan Bank Indonesia tersebut tidak mempengaruhi pergerakan sebagian besar pecahan yang digunakan. Dengan demikian, adanya pergantian kebijakan mengenai peredaran uang akan


diabaikan untuk setiap pecahan yang digunakan. Gambar 4.33 menunjukkan plot *time series* bulanan untuk data *inflow* secara agregat dan tiap pecahan.






**Gambar 4.33** Time Series Plot Data Inflow Secara Agregat dan Tiap Pecahan.

Berdasarkan *time series plot* pada Gambar 4.33, terlihat bahwa sebagian besar pecahan tidak dipengaruhi oleh adanya kebijakan bank Indonesia. Sedangkan plot *time series* untuk *outflow* dapat ditunjukkan oleh Gambar 4.34.





**Gambar 4.34** Time Series Plot Data Outflow Secara Agregat dan Tiap Pecahan.

Berdasarkan plot *time series* pada Gambar 4.34, terlihat bahwa *outflow* untuk pecahan Rp1000,- semakin menurun setiap

tahunnya. Selain itu, adanya perubahan kebijakan bank Indonesia juga tidak berpengaruh pada sebagian besar pecahan yang digunakan. Untuk mendeskripsikan karakteristik data *inflow* dan *outflow*, juga dilakukan analisis statistika deskriptif menggunakan perhitungan *mean*, standar deviasi, median, *skewness*, dan kurtosis seperti pada Tabel 4.12.

**Tabel 4.12** Statistika Deskriptif Data *Inflow* dan *Outflow* (miliar Rp)


Data	Pecahan	Mean	Standar Deviasi	Median	Skewness	Kurtosis
<i>Inflow</i>	1000	95,00	70,11	82,70	0,73	-0,23
	2000	107,20	131,10	14,00	0,95	-0,10
	5000	418,00	204,00	370,50	2,66	9,79
	10000	573,30	252,00	531,30	2,49	9,20
	20000	946,20	486,10	719,40	1,19	0,76
	50000	12382,00	5725,00	12316,00	1,34	3,49
<i>Outflow</i>	100000	12549,00	10836,00	9164,00	2,49	8,05
	1000	91,08	100,67	59,71	1,76	3,81
	2000	148,00	312,40	49,20	3,70	14,58
	5000	464,60	592,20	319,90	4,07	18,72
	10000	624,20	624,40	492,40	3,83	16,69
	20000	969,40	751,80	743,40	1,84	5,29
	50000	13013,00	7027,00	12172,00	1,32	2,86
	100000	14650,00	12827,00	10452,00	2,28	6,80

Berdasarkan Tabel 4.12, dapat diketahui bahwa semakin besar pecahan, nilai rata-rata dan standar deviasi nya akan semakin besar. Hal ini dikarenakan perbedaan satuan data yang digunakan. Kemudian seluruh pecahan yang digunakan memiliki *skewness* lebih dari 0. Bahkan pecahan *outflow* Rp 5.000,00 nilai *skewness* nya adalah 4,07. Hal ini menunjukkan bahwa terdapat kemiringan kekanan untuk seluruh pecahan yang digunakan yang dapat disebabkan oleh adanya *outlier* sehingga sebaran datanya menjadi tidak simetri. Nilai kurtosis menunjukkan keruncingan data apabila dibandingkan dengan distribusi normal. Nilai kurtosis yang positif menunjukkan bahwa data lebih runcing dibandingkan dengan distribusi normal. Sedangkan nilai kurtosis yang negatif menunjukkan distribusi data yang lebih landai dibandingkan dengan distribusi normal. Berdasarkan Tabel 4.12, dapat diketahui bahwa sebagian besar pecahan memiliki nilai kurtosis positif. Hanya pecahan *inflow* Rp 1.000,00 dan *inflow* Rp




2.000,00 yang bernilai negatif. Hal ini menunjukkan bahwa sebagian besar pecahan yang digunakan memiliki distribusi data yang lebih runcing dibandingkan distribusi normal.

Untuk menggambarkan sebaran data dari *inflow* dan *outflow*, dapat dilakukan menggunakan histogram dari data *inflow* dan *outflow*. Dengan menggunakan histogram, juga dapat diketahui apakah sebaran data dari *inflow* dan *outflow* bersifat simetris. Histogram dari data *inflow* dan *outflow* tiap pecahan dapat ditunjukkan pada Gambar 4.35 dan Gambar 4.36.




**Gambar 4.35** Histogram Data *Inflow* Tiap Pecahan.

Berdasarkan Gambar 4.35 dapat diketahui bahwa pada waktu tertentu, terdapat nilai *inflow* yang jauh lebih tinggi dibandingkan waktu yang lain. Begitu pula pada nilai *outflow* pada Gambar 4.36. Apabila dilihat berdasarkan *time series plot* pada Gambar 4.33 dan Gambar 4.34, *inflow* dan *outflow* yang bernilai tinggi ini pada umumnya terjadi pada bulan-bulan sekitar terjadinya hari raya fitri.




**Gambar 4.36** Histogram Data *Outflow* Tiap Pecahan.

Untuk mengetahui apakah terdapat efek variasi kalender berupa hari raya Idul Fitri pada data dan *outflow* di Indonesia, maka dilakukan perbandingan rata-rata *inflow* pada bulan terjadinya hari raya Idul Fitri dan satu bulan setelah hari raya Idul Fitri apabila hari raya Idul Fitri terjadi di minggu ke 1, 2, 3, dan ke 4. Dengan demikian juga akan diketahui apakah terdapat perbedaan peningkatan *inflow* dan *outflow* apabila hari raya Idul Fitri terjadi pada minggu yang berbeda. Perbandingan rata-rata *inflow* hari raya Idul Fitri yang terjadi pada minggu yang berbeda dapat ditunjukkan oleh Gambar 4.37.



**Gambar 4.37** Perbandingan Rata-rata *Inflow* pada Bulan Terjadinya Hari Raya Idul Fitri dan Satu Bulan Setelah Hari Raya Idul Fitri.

Berdasarkan Gambar 4.37, dapat diketahui bahwa hari raya yang terjadi pada minggu yang berbeda juga akan berdampak pada peningkatan *inflow* yang berbeda. Pada umumnya, hari raya yang terjadi diawal bulan akan mengakibatkan peningkatan *inflow* yang lebih tajam untuk *inflow* dibulan tersebut. Sedangkan hari raya Idul Fitri yang terjadi pada akhir bulan akan mengakibatkan *inflow* tertinggi pada satu bulan setelah hari raya. Kemudian, analisis yang sama juga dilakukan pada data *outflow*, namun untuk data *outflow* akan dianalisis peningkatan *outflow* pada satu bulan sebelum hari raya Idul Fitri dan pada saat terjadinya Idul Fitri, yang dapat digambarkan kedalam Gambar 4.38.




**Gambar 4.38** Perbandingan Rata-rata *Outflow* pada Bulan Terjadinya Hari Raya Idul Fitri dan Satu Bulan Sebelum Hari Raya Idul Fitri.

Berdasarkan Gambar 4.38, dapat diketahui bahwa hari raya Idul Fitri yang terjadi pada minggu yang berbeda juga akan mengakibatkan perbedaan peningkatan *outflow* pada bulan terjadinya hari raya Idul Fitri dan satu bulan sebelum hari raya Idul Fitri. Pada bulan terjadinya Idul Fitri, *outflow* tertinggi akan terjadi apabila Idul Fitri terdapat pada akhir bulan. Sedangkan untuk satu bulan sebelum Idul Fitri, *outflow* tertinggi terjadi apabila hari raya Idul Fitri terjadi pada awal bulan.

Dengan demikian, terjadinya hari raya Idul Fitri yang pada minggu yang berbeda akan mengakibatkan perbedaan peningkatan *inflow* maupun *outflow*. Hal ini juga telah sesuai dengan simulasi yang dilakukan dan variabel *dummy* yang digunakan untuk efek variasi kalender. Selanjutnya dilakukan analisis apakah heteroskedastisitas musiman pada *inflow* dan


*outflow* di Indonesia. Identifikasi heteroskedastisitas dilakukan melalui *boxplot* seperti pada data simulasi. Gambar 4.39 merupakan langkah untuk melakukan identifikasi heteroskedastisitas musiman pada pecahan Rp 100.000,-.



**Gambar 4.39** Identifikasi Heteroskedastisitas Musiman pada *Inflow* Pecahan Rp 100.000.

*Boxplot* pada Gambar 4.39(a). merupakan *boxplot* data *inflow* yang dipisahkan berdasarkan bulan. Kemudian pada Gambar 4.39(b), pengaruh kejadian hari raya Idul Fitri telah dihilangkan. Berdasarkan uraian sebelumnya, dapat diketahui bahwa pada kejadian Idul Fitri, nilai *inflow* cenderung meningkat pada bulan terjadinya Idul Fitri dan satu bulan setelah hari raya Idul Fitri. Dengan demikian, efek dari kejadian hari raya Idul Fitri akan dihilangkan terlebih dahulu. Kemudian pada Gambar 4.39(c), pengaruh tren juga telah dihilangkan. Secara jelas, adanya heteroskedastisitas musiman pada *inflow* dapat diketahui melalui *boxplot* pada Gambar 4.39(d). Berdasarkan Gambar 4.39(d), dapat diketahui bahwa pada bulan Januari, variasi *inflow* cenderung lebih tinggi daripada bulan lainnya. Perbedaan variasi setiap bulannya inilah yang dapat disebut sebagai pola heterogen dalam musiman bulan. Secara lengkap, identifikasi heterogen dalam musiman untuk setiap pecahan dapat dilihat pada Lampiran 5.

Pada *outflow*, langkah yang dilakukan untuk mengidentifikasi pola heterogen dalam musiman juga sama dengan langkah pada identifikasi pola heterogen pada *inflow*. Namun, untuk *outflow* pengaruh kejadian hari raya terjadi pada bulan kejadian hari raya dan satu bulan sebelum terjadinya hari raya. Gambar 4.40 merupakan *boxplot* yang digunakan dalam identifikasi heterogen dalam musiman untuk *outflow* pecahan Rp 100.000,-.



**Gambar 4.40** Identifikasi Heteroskedastisitas Musiman pada *Outflow* Pecahan Rp 100.000.

Berdasarkan Gambar 4.40(d), dapat diketahui pula bahwa variasi *outflow* setiap bulannya juga berbeda. Pada bulan Januari (M1) dan Desember (M12), variasi nya cenderung lebih tinggi dibandingkan bulan lainnya. Hal ini diindikasikan oleh semakin lebarnya *boxplot* pada bulan-bulan tersebut.

### 4.3 Peramalan *Inflow* dan *Outflow* dengan ARIMAX

Dalam melakukan peramalan *inflow* dan *outflow* menggunakan ARIMAX, dilakukan pemodelan *time series regression* dengan prediktor berupa variabel *dummy* tren, musiman, dan variasi kalender berupa efek terjadinya hari raya Idul Fitri. Tabel 4.13 menunjukkan hasil estimasi parameter *time series regression* untuk pecahan *outflow* 50.000.

**Tabel 4.13** Estimasi Parameter *Time Series Regression* untuk Pecahan *Outflow* Rp 50.000,-

Variabel	Estimasi	SE	t-value	p-value
$t$	13,79	7,85	1,76	0,08
$M_{1,t}$	5365,31	1337,51	4,01	0,00
$M_{2,t}$	6816,75	1340,89	5,08	0,00
$M_{3,t}$	9777,61	1344,31	7,27	0,00
$M_{4,t}$	10175,83	1347,76	7,55	0,00
$M_{5,t}$	10603,16	1351,26	7,85	0,00
$M_{6,t}$	11982,63	1377,71	8,70	0,00
$M_{7,t}$	12339,53	1427,60	8,64	0,00
$M_{8,t}$	8973,14	1431,14	6,27	0,00
$M_{9,t}$	8825,75	1458,27	6,05	0,00
$M_{10,t}$	9032,66	1500,79	6,02	0,00
$M_{11,t}$	8872,49	1429,95	6,21	0,00
$M_{12,t}$	19760,78	1376,71	14,35	0,00
$V_{1,t}$	-4815,53	3236,46	-1,49	0,14
$V_{2,t}$	7387,35	2652,43	2,79	0,01
$V_{3,t}$	16098,64	2295,46	7,01	0,00
$V_{4,t}$	17703,38	2296,47	7,71	0,00
$V_{1,t-1}$	16848,29	3246,08	5,19	0,00
$V_{2,t-1}$	6161,10	2649,39	2,33	0,02
$V_{3,t-1}$	1663,35	2294,47	0,73	0,47
$V_{4,t-1}$	2017,76	2293,58	0,88	0,38


Setelah diperoleh hasil estimasi parameter, akan dilakukan pengujian residual *time series regression* apakah telah memenuhi asumsi *white noise* dan berdistribusi normal. Tabel 4.14 menunjukkan hasil pengujian independensi residual menggunakan *ljung-box test*.

**Tabel 4.14** *Ljung-box Test Residual Time Series Regression*

Hingga lag ke-	$\chi^2$	p-value
12	363,81	0,00
24	450,33	0,00
36	460,21	0,00
48	520,08	0,00
60	665,79	0,00

Berdasarkan Tabel 4.14, dapat diketahui bahwa residual *time series regression* belum memenuhi asumsi independen. Hal ini ditandai oleh nilai *p-value* yang kurang dari  $\alpha$  ( $\alpha=0,05$ ). Dengan demikian, residual *time series regression* perlu dimodelkan kembali menggunakan metode ARIMA. Langkah awal dalam pemodelan dengan ARIMA adalah melakukan

identifikasi stasioneritas data. Dalam melakukan identifikasi stasioneritas data dalam *mean*, dapat dilakukan dengan menggunakan plot ACF dan pengujian dickey fuller. Gambar 4.41 menunjukkan plot ACF dan PACF dari residual *time series regression*.




**Gambar 4.41** Plot ACF dan PACF dari Residual *Time Series Regression*.

Pengujian stasioneritas residual *time series regression* dapat ditunjukkan oleh Tabel 4.15.

**Tabel 4.15** Pengujian stasioneritas residual *time series regression*

Data	Dickey-Fuller	<i>p-value</i>	Kesimpulan
Residual TSR	-1,53	0,77	Tidak Stasioner
Diff Residual TSR	-7,55	0,00	Stasioner

Gambar 4.41 menunjukkan bahwa plot ACF turun lambat, yang menandakan bahwa residual *time series regression* belum stasioner dalam *mean*. Hal ini juga didukung oleh pengujian stasioneritas menggunakan uji dickey fuller. *P-value* yang diperoleh adalah 0,77. Dengan hipotesis awal adalah data belum stasioner maka hipotesis awal gagal ditolak, sehingga residual *time series regression* belum memenuhi stasioneritas dalam *mean*. Untuk mengatasi hal tersebut, dilakukan *differencing* pada orde non musiman dan dilakukan pengujian stasioneritas kembali seperti ditunjukkan pada Tabel 4.15. Berdasarkan Tabel 4.15, dapat diketahui bahwa data *differencing* dari residual *time series regression* telah stasioner dalam *mean*. Kemudian akan diidentifikasi plot ACF dan PACF untuk menduga orde ARIMA. Gambar 4.42 menunjukkan plot ACF dan PACF dari data residual *time series regression* yang telah *didifferencing*.



**Gambar 4.42** Plot ACF dan PACF dari data residual *time series regression* yang telah *didifferencing*.

Gambar 4.42 menunjukkan bahwa terdapat beberapa kemungkinan model ARIMA yang terbentuk, seperti ditunjukkan pada Tabel 4.16.

**Tabel 4.16.** Pembentukan model ARIMA

Model	Parameter	Estimasi	<i>p-value</i>	aic
ARIMA (3,1,0)	$\phi_1$	-0,84	0,00	2941.38
	$\phi_2$	-0,50	0,02	
	$\phi_3$	-0,23	0,00	
ARIMA ([1,2,3,11],1,0)	$\phi_1$	-0,86	0,00	2937.58
	$\phi_2$	-0,51	0,00	
	$\phi_3$	-0,25	0,00	
	$\phi_{11}$	-0,14	0,01	

Pemilihan model ARIMA terbaik dapat dilakukan berdasarkan nilai aic terkecil. Dengan demikian, model ARIMA terpilih adalah ARIMA ([1,2,3,11],1,0). Selanjutnya dilakukan pengujian residual ARIMA apakah telah memenuhi asumsi *white noise* dan berdistribusi normal. Hasil pengujian independensi residual model ARIMA dapat ditunjukkan oleh Tabel 4.17.

**Tabel 4.17** Pengujian *Ljung-Box* Residual Model ARIMA

Hingga lag ke-	$\chi^2$	<i>p-value</i>
12	16,99	0,15
24	32,83	0,11
36	40,49	0,28
48	49,42	0,42
60	57,41	0,57

Berdasarkan hasil pengujian *ljung-box*, dapat diketahui bahwa residual telah memenuhi asumsi independen hingga lag 60. Selanjutnya dilakukan pengujian apakah residual ARIMA bersifat identik menggunakan uji *lagrange multiplier*. Tabel 4.18 menunjukkan hasil pengujian *lagrange multiplier* untuk residual ARIMA pada pecahan *outflow* Rp 50.000,00.



**Tabel 4.18** Pengujian *Lagrange Multiplier* Residual Model ARIMA

Hingga lag ke-	$\chi^2$	<i>p-value</i>	Hingga lag ke-	$\chi^2$	<i>p-value</i>
1	0,16	0,69	7	7,48	0,38
2	0,15	0,93	8	8,75	0,36
3	0,25	0,97	9	9,00	0,44
4	0,97	0,91	10	10,66	0,38
5	2,68	0,75	11	10,74	0,47
6	5,58	0,47	12	14,16	0,29

Berdasarkan pengujian menggunakan *lagrange multiplier*, diperoleh bahwa *p-value* hingga lag ke-12 lebih besar dari  $\alpha$  ( $\alpha=0,05$ ). Dengan hipotesis awal data tidak mengandung heteroskedastisitas, maka hipotesis awal gagal ditolak. Dengan demikian, residual ARIMA memenuhi asumsi identik. Kemudian, dilakukan pengujian asumsi distribusi normal pada residual ARIMA dan diperoleh *p-value* sebesar 0,253. Dengan hipotesis awal data mengikuti distribusi normal, maka hipotesis awal gagal ditolak. Dengan demikian, residual ARIMA memenuhi asumsi normalitas.

Berdasarkan cek diagnosa yang telah dilakukan, maka dapat disimpulkan bahwa residual ARIMA telah memenuhi asumsi independen, identik, dan berdistribusi normal. Dengan proses yang sama, peramalan menggunakan ARIMAX juga dilakukan untuk 13 pecahan lainnya. Apabila asumsi identik tidak terpenuhi, maka pemodelan dilanjutkan menggunakan metode GARCH. Secara lengkap, hasil pemodelan untuk seluruh pecahan menggunakan ARIMAX dapat dilihat pada Lampiran 6. Berdasarkan hasil pemodelan tersebut, diperoleh model terbaik ARIMA untuk masing-masing pecahan seperti ditunjukkan pada Tabel 4.19.

**Tabel 4.19** Model Terbaik ARIMA untuk Masing-masing Pecahan

Data	Model	Residual White noise
$Y_1$	ARIMA ([1,11,12,13],0,0)	Ya
$Y_2$	ARIMA (1,0,0)	Ya
$Y_3$	ARIMA ([1,2,12,14],0,[23]) - GARCH ([11],0)	Tidak
$Y_4$	ARIMA (0,0,1)(0,0,2) <sup>12</sup> - GARCH ([11],0)	Tidak
$Y_5$	ARIMA (2,1,0) - GARCH (1,0)	Tidak
$Y_6$	ARIMA (2,1,0)	Tidak DN
$Y_7$	ARIMA (4,1,0) - GARCH ([12],[12])	Tidak

**Tabel 4.19** Model Terbaik ARIMA untuk Masing-masing Pecahan (*Lanjutan*)

Data	Model	Residual White noise
$Y_8$	ARIMA (1,0,0) - GARCH (1,0)	Tidak
$Y_9$	ARIMA (1,0,0) - GARCH (1,0)	Tidak
$Y_{10}$	ARIMA ([11,12,23],0,0) - GARCH ([11],0)	Tidak
$Y_{11}$	ARIMA ([11,23],0,0) - GARCH ([11],0)	Tidak
$Y_{12}$	ARIMA ([1,2,3,22],1,0) - GARCH (1,0)	Tidak
$Y_{13}$	ARIMA ([1,2,3,11],1,0)	Ya
$Y_{14}$	ARIMA (4,1,0)(1,0,0) <sup>12</sup>	Ya

Berdasarkan model terbaik seperti pada Tabel 4.19, dapat diketahui bahwa setiap pecahan memiliki karakteristik yang berbeda. Beberapa pecahan *inflow* dan *outflow* memiliki pola musiman bulan yang ditandai oleh penggunaan model GARCH subset orde 12, dan juga terdapat beberapa pecahan lain yang tidak mengandung heteroskedastisitas pada pola musimannya. Untuk setiap pecahan, model *time series regression* dengan residual mengikuti model seperti pada Tabel 4.19 dapat dituliskan kedalam persamaan:

- a. Persamaan model ARIMAX data *inflow* pecahan Rp 1.000,00

$$\begin{aligned}\hat{Y}_{1,t} = & -1,23t + 233,61M_{1,t} + 219,05M_{2,t} + 216,39M_{3,t} + 197,11M_{4,t} + \\ & 188,58M_{5,t} + 176,25M_{6,t} + 175,05M_{7,t} + 168,09M_{8,t} + 163,35M_{9,t} + \\ & 177,72M_{10,t} + 201,64M_{11,t} + 217,64M_{12,t} + 20,85V_{1,t} - 0,59V_{2,t} - \\ & 20,66V_{3,t} - 40,92V_{4,t} + 74,28V_{1,t+1} + 49,21V_{2,t+1} + 46,80V_{3,t+1} + \\ & 30,83V_{4,t+1} + 0,36Y_{t-1} + 0,32Y_{t-11} + 0,37Y_{t-12} - 0,26Y_{t-13}\end{aligned}$$

- b. Persamaan model ARIMAX data *inflow* pecahan Rp 2.000,00

$$\begin{aligned}\hat{Y}_{2,t} = & 3,32t + -179,45M_{1,t} + 195,80M_{2,t} - 204,50M_{3,t} + 197,11M_{4,t} + \\ & 188,58M_{5,t} + 176,25M_{6,t} + 175,05M_{7,t} + 168,09M_{8,t} + 163,35M_{9,t} + \\ & 177,72M_{10,t} + 201,64M_{11,t} + 217,64M_{12,t} + 20,85V_{1,t} - 0,59V_{2,t} - \\ & 20,66V_{3,t} - 40,92V_{4,t} + 74,28V_{1,t+1} + 49,21V_{2,t+1} + 46,80V_{3,t+1} + \\ & 30,83V_{4,t+1} + 0,36Y_{t-1} + 0,32Y_{t-11} + 0,37Y_{t-12} - 0,26Y_{t-13}\end{aligned}$$

- c. Persamaan model ARIMAX data *inflow* pecahan Rp 5.000,00

$$\begin{aligned}\hat{Y}_{3,t} = & 1,32t + 372,40M_{1,t} + 308,32M_{2,t} + 291,22M_{3,t} + 242,28M_{4,t} + \\ & 207,76M_{5,t} + 188,53M_{6,t} + 202,18M_{7,t} + 307,17M_{8,t} + 391,22M_{9,t} + \\ & 361,26M_{10,t} + 324,21M_{11,t} + 256,95M_{12,t} + 100,22V_{1,t} - 137,58V_{2,t} - \\ & 158,79V_{3,t} - 192,59V_{4,t} + 210,68V_{1,t+1} + 184,06V_{2,t+1} + 329,54V_{3,t+1} + \\ & 224,31V_{4,t+1} + 0,30Y_{t-1} + 0,23Y_{t-11} + 0,52Y_{t-12} - 0,35Y_{t-14} - 0,73a_{t-23}\end{aligned}$$

d. Persamaan model ARIMAX data *inflow* pecahan Rp 10.000,00

$$\begin{aligned}\hat{Y}_{4,t} = & 1,05t + 582,24M_{1,t} + 475,59M_{2,t} + 456,61M_{3,t} + 401,79M_{4,t} + \\ & 363,29M_{5,t} + 335,08M_{6,t} + 367,15M_{7,t} + 491,19M_{8,t} + \\ & 537,63M_{9,t} + 512,23M_{10,t} + 469,39M_{11,t} + 380,54M_{12,t} + \\ & 66,63V_{1,t} - 71,14V_{2,t} - 101,50V_{3,t} - 195,41V_{4,t} + 182,00V_{1,t+1} + \\ & 233,11V_{2,t+1} + 524,91V_{3,t+1} + 494,00V_{4,t+1} + Y_{t-1} - 0,77a_{t-1} + \\ & 0,71a_{t-2} - 0,55a_{t-3} + 0,33a_{t-4} - 0,25a_{t-5}\end{aligned}$$

e. Persamaan model ARIMAX data *inflow* pecahan Rp 20.000,00

$$\begin{aligned}\hat{Y}_{5,t} = & -7,05t + 1680,32M_{1,t} + 1467,96M_{2,t} + 1447,34M_{3,t} + \\ & 1377,35M_{4,t} + 1336,02M_{5,t} + 1325,72M_{6,t} + 1381,59M_{7,t} + \\ & 1481,29M_{8,t} + 1495,00M_{9,t} + 1516,72M_{10,t} + 1500,61M_{11,t} + \\ & 1402,62M_{12,t} + 534,14V_{1,t} - 75,77V_{2,t} - 124,01V_{3,t} - 225,66V_{4,t} + \\ & 284,91V_{1,t+1} + 93,67V_{2,t+1} + 728,51V_{3,t+1} + 935,60V_{4,t+1} + Y_{t-1} + \\ & 0,43Y_{t-2} + 0,18Y_{t-3} + 0,39Y_{t-4}\end{aligned}$$

f. Persamaan model ARIMAX data *inflow* pecahan Rp 50.000,00

$$\begin{aligned}\hat{Y}_{6,t} = & 16t + 15243,0M_{1,t} + 9727,5M_{2,t} + 9173,9M_{3,t} + 9129,5M_{4,t} + \\ & 8666,0M_{5,t} + 8659,0M_{6,t} + 10278,9M_{7,t} + 10700,0M_{8,t} + \\ & 9034,5M_{9,t} + 10666,0M_{10,t} + 8378,8M_{11,t} + 6781,3M_{12,t} + \\ & 126999V_{1,t} + 9188,5V_{2,t} + 7252,9V_{3,t} - 2568,0V_{4,t} + 563,6V_{1,t+1} - \\ & 757,8V_{2,t+1} + 6425,0V_{3,t+1} + 15642,4V_{4,t+1} + 0,27Y_{t-1} + 0,41Y_{t-2} - \\ & 0,32Y_{t-3}\end{aligned}$$

g. Persamaan model ARIMAX data *inflow* pecahan Rp 100.000,00

$$\begin{aligned}\hat{Y}_{7,t} = & 129,02t + 7822,14M_{1,t} + 477,28M_{2,t} - 578,25M_{3,t} - \\ & 918,87M_{4,t} - 1130,84M_{5,t} - 1329,95M_{6,t} + 825,95M_{7,t} + \\ & 2960,37M_{8,t} - 1728,94M_{9,t} - 134,85M_{10,t} - 3062,16M_{11,t} - \\ & 5694,64M_{12,t} + 12122,48V_{1,t} + 15549,24V_{2,t} + 11413,76V_{3,t} - \\ & 2055,48V_{4,t} + 2697,41V_{1,t+1} - 845,33V_{2,t+1} + 5408,14V_{3,t+1} + \\ & 22368,04V_{4,t+1} + 0,11Y_{t-1} + 0,25Y_{t-2} + 0,17Y_{t-3} + 0,15Y_{t-4} - \\ & 0,33Y_{t-5}\end{aligned}$$

h. Persamaan model ARIMAX data *outflow* pecahan Rp 1.000,00

$$\begin{aligned}\hat{Y}_{8,t} = & -1,43t + 188,31M_{1,t} + 174,74M_{2,t} + 177,00M_{3,t} + 177,46M_{4,t} + \\ & 179,35M_{5,t} + 180,65M_{6,t} + 165,61M_{7,t} + 209,69M_{8,t} + \\ & 219,62M_{9,t} + 228,33M_{10,t} + 186,02M_{11,t} + 196,82M_{12,t} - \\ & 36,18V_{1,t} + 78,33V_{2,t} + 126,91V_{3,t} + 242,08V_{4,t} + 340,34V_{1,t-1} + \\ & 109,58V_{2,t-1} + 45,65V_{3,t-1} + 50,76V_{4,t-1} + 0,56Y_{t-1}\end{aligned}$$

- i. Persamaan model ARIMAX data *outflow* pecahan Rp 2.000,00

$$\begin{aligned}\hat{Y}_{9,t} = & 1,62t - 52,93M_{1,t} - 58,79M_{2,t} - 53,58M_{3,t} - 28,93M_{4,t} + \\ & 29,87M_{5,t} + 80,03M_{6,t} - 22,96M_{7,t} - 297,26M_{8,t} - \\ & 119,48M_{9,t} - 111,97M_{10,t} - 95,41M_{11,t} - 13,82M_{12,t} + \\ & 220,22V_{2,t} + 769,01V_{3,t} + 1523,51V_{4,t} + 1458,71V_{2,t-1} + \\ & 760,29V_{3,t-1} + 168,77V_{4,t-1} - 0,36Y_{t-1}\end{aligned}$$

- j. Persamaan model ARIMAX data *outflow* pecahan Rp 5.000,00

$$\begin{aligned}\hat{Y}_{10,t} = & 1,47t + 175,35M_{1,t} + 148,51M_{2,t} + 159,60M_{3,t} + 205,35M_{4,t} + \\ & 253,25M_{5,t} + 381,42M_{6,t} + 546,70M_{7,t} + 176,93M_{8,t} + 3,22M_{9,t} - \\ & 117,11M_{10,t} - 85,85M_{11,t} + 21,28M_{12,t} + 238,86V_{1,t} + 298,49V_{2,t} + \\ & 987,56V_{3,t} + 1610,17V_{4,t} + 1383,84V_{1,t-1} + 1655,93V_{2,t-1} + \\ & 1048,22V_{3,t-1} + 318,11V_{4,t-1} + 0,17Y_{t-11} + 0,21Y_{t-12} + 0,46Y_{t-13}\end{aligned}$$

- k. Persamaan model ARIMAX data *outflow* pecahan Rp 10.000,00

$$\begin{aligned}\hat{Y}_{11,t} = & 1,57t + 391,33M_{1,t} + 295,28M_{2,t} + 323,03M_{3,t} + 379,68M_{4,t} + \\ & 412,27M_{5,t} + 575,71M_{6,t} + 677,42M_{7,t} + 340,88M_{8,t} + \\ & 37,11M_{9,t} - 41,19M_{10,t} + 27,33M_{11,t} + 416,88M_{12,t} + 164,69V_{1,t} + \\ & 220,33V_{2,t} + 920,67V_{3,t} + 1940,23V_{4,t} + 886,05V_{1,t-1} + \\ & 1632,63V_{2,t-1} + 1139,88V_{3,t-1} + 457,25V_{4,t-1} + 0,25Y_{t-11} + 0,31Y_{t-23}\end{aligned}$$

- l. Persamaan model ARIMAX data *outflow* pecahan Rp 20.000,00

$$\begin{aligned}\hat{Y}_{12,t} = & -6,50t + 1295,49M_{1,t} + 1126,73M_{2,t} + 1126,90M_{3,t} + \\ & 1298,94M_{4,t} + 1358,82M_{5,t} + 1587,37M_{6,t} + 1586,86M_{7,t} + \\ & 1244,51M_{8,t} + 1147,60M_{9,t} + 1077,28M_{10,t} + 1096,85M_{11,t} + \\ & 1587,06M_{12,t} - 275,33V_{1,t} + 23,62V_{2,t} + 1214,07V_{3,t} + 1937,21V_{4,t} + \\ & 1921,11V_{1,t-1} + 1265,89V_{2,t-1} + 1391,12V_{3,t-1} + 567,22V_{4,t-1} + \\ & 0,30Y_{t-1} + 0,20Y_{t-2} + 0,26Y_{t-3} + 0,25Y_{t-4} - 0,28Y_{t-22} + 0,28Y_{t-23}\end{aligned}$$

- m. Persamaan model ARIMAX data *outflow* pecahan  
Rp 50.000,00

$$\begin{aligned}\hat{Y}_{13,t} = & 13,79t + 5365,31M_{1,t} + 6816,75M_{2,t} + 9777,61M_{3,t} + 10175,83M_{4,t} + \\ & 10603,16M_{5,t} + 11982,63M_{6,t} + 12339,53M_{7,t} + \\ & 8973,14M_{8,t} + 8825,75M_{9,t} + 9032,66M_{10,t} + 8872,49M_{11,t} - \\ & 19760,78M_{12,t} - 4815,53V_{1,t} + 7387,35V_{2,t} + 16098,64V_{3,t} + \\ & 17703,38V_{4,t} + 16848,29V_{1,t-1} + 6161,10V_{2,t-1} + 1663,35V_{3,t-1} + \\ & 2017,76V_{4,t-1} + 0,14Y_{t-1} + 0,35Y_{t-2} + 0,26Y_{t-3} + 0,25Y_{t-4} - \\ & 0,15Y_{t-11} + 0,15Y_{t-12}\end{aligned}$$

n. Persamaan model ARIMAX data *outflow* pecahan  
Rp 100.000,00

$$\begin{aligned}\hat{Y}_{14,t} = & 148,85t + 5866,76M_{1,t} + 3983,26M_{2,t} + 1120,26M_{3,t} + \\ & 415,81M_{4,t} + 402,39M_{5,t} + 2012,53M_{6,t} + 5208,02M_{7,t} + \\ & 1649,11M_{8,t} + 1924,04M_{9,t} + 1450,97M_{10,t} + 2551,97M_{11,t} + \\ & 13021,94M_{12,t} - 1554,07V_{1,t} + 5962,32V_{2,t} + 18123,55V_{3,t} + \\ & 21085,49V_{4,t} + 15316,96V_{1,t-1} + 8019,37V_{2,t-1} + 442,61V_{3,t-1} + \\ & 3175,22V_{4,t-1} + 0,08Y_{t-1} + 0,28Y_{t-2} + 0,19Y_{t-3} + 0,23Y_{t-4} + \\ & 0,22Y_{t-5} + 0,71Y_{t-12} + 0,06Y_{t-13} - 0,66Y_{t-14} - 0,46Y_{t-15} - \\ & 0,32Y_{t-16} - 0,16Y_{t-17}\end{aligned}$$

Setelah diperoleh persamaan untuk masing-masing pecahan, maka dilakukan evaluasi kebaikan model menggunakan kriteria RMSE, MAE, MdAE, MdAPE dan MAPE untuk data *training* dan *testing*, serta dilakukan perbandingan data aktual dan ramalan berdasarkan plot. Tabel 4.20 menunjukkan nilai kriteria yang diperoleh untuk seluruh pecahan.


**Tabel 4.20** Perbandingan Kriteria Model ARIMAX Data *Inflow* dan *Outflow*


Data	Pecahan	RMSE	MAE	MdAE	MdAPE	MAPE
<i>Training</i>	$Y_1$	19,76	14,50	11,67	12,76	23,08
	$Y_2$	37,22	28,40	19,68	13,32	64,13
	$Y_3$	68,45	49,24	34,01	9,78	12,60
	$Y_4$	112,94	77,02	53,60	10,68	13,86
	$Y_5$	166,62	121,33	81,64	10,82	13,88
	$Y_6$	2303,87	1586,60	990,32	9,68	14,47
	$Y_7$	4518,88	3054,99	2263,60	23,28	34,70
	$Y_8$	34,22	23,16	14,23	23,05	88,64
	$Y_9$	67,08	21,99	26,21	16,68	28,75
	$Y_{10}$	209,84	137,02	87,75	24,18	40,99
	$Y_{11}$	272,04	172,80	107,80	22,28	36,98
	$Y_{12}$	267,55	194,78	128,22	18,80	31,58
	$Y_{13}$	3052,73	2245,51	1495,67	15,15	21,71
	$Y_{14}$	4139,83	3017,51	2225,49	19,35	34,30
<i>Testing</i>	$Y_1$	15,89	12,42	8,36	71,87	82,76
	$Y_2$	83,03	77,74	70,34	26,03	31,58
	$Y_3$	117,27	78,88	57,02	12,72	12,90
	$Y_4$	223,45	122,89	43,05	7,36	11,71
	$Y_5$	352,98	242,40	139,42	18,03	22,53
	$Y_6$	3767,76	2667,62	1548,66	11,85	12,62
	$Y_7$	11887,99	7445,63	3923,95	17,31	20,93
	$Y_8$	87,84	47,02	22,70	873,22	1166,80
	$Y_9$	438,31	206,03	69,11	52,48	80,48


**Tabel 4.20** Perbandingan Kriteria Model ARIMAX Data *Inflow* dan *Outflow*  
(*Lanjutan*)

Data	Pecahan	RMSE	MAE	MdAE	MdAPE	MAPE
<i>Testing</i>	$Y_{10}$	539,42	325,66	118,18	39,00	91,81
	$Y_{11}$	736,00	434,00	174,86	39,57	94,90
	$Y_{12}$	772,42	480,62	260,78	39,07	73,35
	$Y_{13}$	2925,16	2569,97	2461,70	14,14	16,83
	$Y_{14}$	12615,51	7821,79	3797,41	14,43	28,38


Berdasarkan Tabel 4.20, dapat diketahui bahwa model yang terbentuk cenderung memiliki tingkat kesalahan yang tinggi. Nilai MAPE dan MdAPE untuk data *testing* cenderung tinggi untuk seluruh pecahan. Kemudian dilakukan perbandingan data aktual dan ramalan, yang ditunjukkan oleh Gambar 4.43.











**Gambar 4.43** Perbandingan Data Aktual dan Ramalan Model ARIMAX untuk Data *Inflow* dan *Outflow*.

Berdasarkan Gambar 4.43, dapat diketahui bahwa untuk data *training*, hasil ramalan cenderung dapat mengikuti pola data aktual dengan baik. Namun, untuk data *testing*, pada beberapa pecahan, masih terdapat model yang tidak dapat menangkap pola variasi kalender dengan baik, yakni *inflow* pada pecahan Rp 20.000,00 dan Rp 100.000,00 serta *outflow* Rp 2.000,- dan Rp 100.000,-. Hasil peramalan *interval* yang terbentuk juga telah dapat memuat sebagian besar data *testing*. Bahkan pada pecahan *inflow* Rp 1.000,00 dan *outflow* Rp 50.000,00, seluruh data

*testing* yang digunakan termuat ke dalam batas peramalan *interval* yang terbentuk.

#### 4.4 Peramalan *Inflow* dan *Outflow* dengan *Neural Network*

Dalam peramalan menggunakan *neural network*, salah satu komponen penting yang dapat memengaruhi akurasi peramalan adalah pemilihan *input* yang digunakan. Pemilihan *input* dapat dilakukan dilakukan melalui beberapa cara, salah satunya adalah berdasarkan *lag* signifikan pada plot PACF data yang telah stasioner (Crone & Kourentzes, 2009). Dengan demikian, perlu dilakukan pengujian stasioneritas pada data *inflow* dan *outflow* untuk memperoleh kemungkinan *input* yang digunakan. Tabel 4.21 merupakan hasil pengujian stasioneritas menggunakan uji dickey fuller.

**Tabel 4.21** Pengujian Stasioneritas Data *Inflow* dan *Outflow*


Data	Dickey-Fuller	P-value	Keterangan
$Y_1$	-6,98	0,00	Stasioner
$Y_2$	-3,34	0,07	Tidak Stasioner
$Y_3$	-5,11	0,00	Stasioner
$Y_4$	-3,83	0,02	Stasioner
$Y_5$	-2,20	0,49	Tidak Stasioner
$Y_6$	-2,27	0,46	Tidak Stasioner
$Y_7$	-2,61	0,32	Tidak Stasioner
$Y_8$	-5,51	0,00	Stasioner
$Y_9$	-6,58	0,00	Stasioner
$Y_{10}$	-7,19	0,00	Stasioner
$Y_{11}$	-6,17	0,00	Stasioner
$Y_{12}$	-3,84	0,02	Stasioner
$Y_{13}$	-3,26	0,08	Tidak Stasioner
$Y_{14}$	-3,71	0,03	Stasioner

Tabel 4.21 menunjukkan bahwa terdapat beberapa pecahan yang belum stasioner dalam *mean*, yakni pecahan *inflow* Rp.2000,00; Rp.20.000,00; Rp.50.000,00; Rp.100.000,00 serta pecahan *outflow* Rp.50.000,00. Sehingga perlu dilakukan *differencing* pada pecahan tersebut. Pengujian stasioneritas setelah dilakukan *differencing* pada pecahan yang belum stasioner dapat ditunjukkan oleh Tabel 4.22.

**Tabel 4.22** Pengujian Stasioneritas Data *Inflow* dan *Outflow* yang telah di *Differencing*

Data	Dickey-Fuller	P-value	Keterangan
$Y_2$	-7,60	0,01	Stasioner
$Y_5$	-7,41	0,01	Stasioner
$Y_6$	-8,68	0,01	Stasioner
$Y_7$	-11,92	0,01	Stasioner
$Y_{13}$	-8,03	0,01	Stasioner

Berdasarkan Tabel 4.22, dapat diketahui bahwa seluruh pecahan telah stasioner dalam *mean*. Selanjutnya dilakukan identifikasi kombinasi *input* yang memungkinkan berdasarkan *lag* PACF yang signifikan. Secara lengkap, PACF untuk seluruh pecahan *inflow* dan *outflow* dapat dilihat pada Lampiran 7. PACF untuk data *inflow* pecahan Rp 1000,00 dapat ditunjukkan oleh Gambar 4.44.



**Gambar 4.44** PACF Data *Inflow* Pecahan Rp.1000,00.

Berdasarkan PACF pada Gambar 4.44, dapat diketahui bahwa *lag* yang signifikan adalah *lag* 1, 11, 12, dan 13. Dengan demikian, kombinasi *input* yang digunakan adalah *lag* 1; *lag* 1, 11, dan 13; serta *lag* 1, 11, 12, dan 13. Untuk 13 pecahan lainnya, kombinasi *input* yang digunakan ditunjukkan oleh Tabel 4.23.

**Tabel 4.23** Kombinasi *Input* Model *Neural Network* Data *Inflow* dan *Outflow*

<i>Inflow</i>			<i>Outflow</i>		
Data	Lag signifikan pada PACF	Kombinasi <i>input</i>	Data	Lag signifikan pada PACF	Kombinasi <i>input</i>
$Y_1$	1,11,13, dan 12	1 1,11, dan 13 1,11,12, dan 13	$Y_8$	1,11,12, dan 13	1 12 1,11,12, dan 13
diff $Y_2$	10 dan 12	1 1,10,11,12, dan 13	$Y_9$	1,11, dan 12	12 1,11, dan 12

**Tabel 4.23** Kombinasi *Input* Model *Neural Network* Data *Inflow* dan *Outflow* (Lanjutan)

<i>Inflow</i>			<i>Outflow</i>		
$Y_3$	1,11,12, dan 13	1 12 1,11,12, dan 13	$Y_{10}$	1, 11 dan 12	12 1,11, dan 12
$Y_4$	1,11,12, dan 13	1 12 1,11,12, dan 13	$Y_{11}$	1,11 dan 12	12 1,11, dan 12
diff $Y_5$	1, 2,10,11, dan 12	1 1,11,12,13 1,2,3,10,11,12, dan 13	$Y_{12}$	1,11, dan 12	1 11 dan 12 1, 11, dan 12
diff $Y_6$	1,2, dan 11	1 12 1,2,3,11, dan 12	diff $Y_{13}$	1,2, dan 11	11 dan 12 1,2,3,11, dan 12
diff $Y_7$	1,2,4,5, dan 11	1 12 1,2,3,4,5,6,11, dan 12	$Y_{14}$	1,2, dan 12	12 1,2,3, dan 12

Selanjutnya dilakukan pengujian linieritas menggunakan uji terasvirta untuk kombinasi *input*. Secara lengkap, hasil pengujian terasvirta dapat ditunjukkan pada Lampiran 8. Hasil pengujian terasvirta *inflow* pecahan 1.000 ditunjukkan pada Tabel 4.24.

**Tabel 4.24** Pengujian Linieritas *Input* untuk Data *Inflow* Pecahan Rp.1000,00

Lag <i>input</i>	$\chi^2$	<i>p-value</i>	kesimpulan
1	9,923	0,007	nonlinier
1,11, dan 13	81,533	0,000	nonlinier
1,11,12, dan 13	115,473	0,000	nonlinier


Tabel 4.24 menunjukkan bahwa seluruh kombinasi *input* memiliki hubungan nonlinier dengan *output*. Kemudian, pada setiap *input* dicobakan kombinasi *neuron* sebanyak 1, 2, 3, 4, 5, 10, dan 15 *neuron*. Setiap kombinasi *neuron* dan *input* akan dilakukan replikasi sebanyak 10 kali. Dengan demikian, model yang terbentuk untuk metode *neural network* adalah sebanyak 36 kombinasi *input* x 7 kombinasi *neuron* x 10 replikasi = 2520 model *neural network*. Untuk setiap pecahan akan dipilih satu model *neural network* terbaik dengan *input* dan *neuron* optimal. Pemilihan model terbaik ini didasarkan pada tingkat kesalahan pada data *testing*, yang dapat dilihat pada Lampiran 10. Nilai tingkat kesalahan untuk seluruh kombinasi *input* dan *neuron* pada *inflow* pecahan Rp 1.000,- dapat ditunjukkan oleh Tabel 4.25.

**Tabel 4.25** Perbandingan Kriteria dalam Pemilihan *Neuron Model Neural Network* untuk Data *Inflow* Pecahan Rp 1.000,00

Data	Lag input	Neuron	RMSE	MAE	MdAE	MdAPE	MAPE
Training	1	1	17,67	13,00	11,11	14,69	21,54
		2	12,52	9,01	6,98	10,37	14,24
		3	8,22	5,86	4,39	7,58	10,06
		4	9,16	5,63	3,72	4,88	9,51
		5	7,12	4,75	2,85	4,44	9,33
		10	5,75	4,05	2,97	4,48	6,88
		15	6,30	4,15	2,34	5,21	7,68
	1,11, dan 13	1	14,88	11,28	9,52	12,74	18,64
		2	11,01	7,76	6,07	7,40	12,47
		3	7,32	4,77	2,86	4,79	7,78
		4	7,67	4,80	2,94	4,70	7,20
		5	6,34	3,97	2,24	4,11	7,27
		10	5,42	3,37	1,96	3,12	7,18
		15	5,16	3,22	1,68	4,30	6,58
	1,11,12, dan 13	1	13,85	10,38	8,41	10,96	16,26
		2	11,22	7,90	6,02	8,40	13,21
		3	8,43	5,60	3,64	5,73	8,78
		4	6,54	4,46	2,63	5,60	7,19
		5	6,46	4,62	3,54	4,80	7,32
		10	4,28	2,93	1,95	2,41	5,24
		15	4,74	3,02	1,80	2,71	5,80
Testing	1	1	12,74	10,94	11,85	72,39	75,17
		2	<b>3,49</b>	<b>3,03</b>	<b>2,57</b>	<b>18,08</b>	<b>21,07</b>
		3	40,81	22,12	9,21	60,37	175,88
		4	6,55	6,04	6,50	42,83	45,22
		5	49,85	26,58	6,61	60,74	164,00
		10	4,19	3,65	2,90	19,46	27,35
		15	48,94	32,54	12,08	92,09	234,96
	1, 11, dan 13	1	7,97	6,75	6,43	40,16	45,26
		2	4,68	4,15	4,04	26,02	30,21
		3	10,79	8,54	7,46	47,49	58,08
		4	51,09	37,22	29,36	261,08	260,26
		5	62,28	41,47	8,07	68,52	266,68
		10	85,14	42,44	3,88	33,37	254,40
		15	8,06	6,44	6,34	38,06	43,49
	1, 11, 12, dan 13	1	5,02	4,57	3,93	24,80	30,70
		2	4,49	3,92	3,77	25,87	28,11
		3	45,76	21,25	6,24	50,30	128,55
		4	27,88	18,70	13,19	91,95	147,83
		5	53,06	34,24	12,75	111,12	218,95
		10	59,00	44,06	35,44	330,58	305,82
		15	37,58	18,66	3,78	27,91	115,36

Keterangan : angka yang dicetak tebal merupakan nilai minimum untuk setiap kriteria

Tabel 4.25 menunjukkan bahwa berdasarkan kelima kriteria yang digunakan model terbaik diperoleh dengan menggunakan *input* berupa variabel *dummy* dan *lag* 1, serta *neuron* sebanyak 2. Arsitektur model *neural network* untuk *inflow* pecahan Rp 1.000,00 dapat ditunjukkan pada Gambar 4.45.



**Gambar 4.45** Arsitektur Model *Neural Network* untuk *Inflow* Rp 1.000,00.

Dengan arsitektur pada Gambar 4.45, diperoleh hasil estimasi pembobot untuk model *neural network* seperti pada Tabel 4.26.

**Tabel 4.26** Estimasi Parameter Pembobot *Neural Network* untuk *Inflow* Pecahan Rp 1.000,00

Prediktor		Hidden Layer		Output Layer
		Neuron 1	Neuron 2	
Input layer	Intercept	0,499	-1,200	
	$Y_{t-1}$	0,008	0,010	
	$t$	-0,017	0,020	
	$M_1$	0,498	20,391	
	$M_2$	0,592	1,233	
	$M_3$	0,499	1,407	
	$M_4$	0,439	1,089	
	$M_5$	0,398	1,046	
	$M_6$	0,244	1,057	
	$M_7$	0,078	1,276	
	$M_8$	0,139	1,136	
	$M_9$	0,075	1,234	
	$M_{10}$	0,449	0,779	
	$M_{11}$	0,702	0,805	
	$M_{12}$	0,593	1,049	
	$V_{1,x}$	-0,083	0,218	
	$V_{2,x}$	0,369	-0,830	
	$V_{3,x}$	-0,200	-0,279	
	$V_{4,x}$	0,300	-0,884	
	$V_{1,x+1}$	0,091	18,477	
	$V_{2,x+1}$	0,409	-0,328	
	$V_{3,x+1}$	0,034	18,825	
	$V_{4,x+1}$	0,213	0,170	
Hidden Layer	Intercept			-0,917
	Neuron 1			2,463
	Neuron 2			2,028

Pada Tabel 4.26, diperoleh bahwa estimasi pembobot untuk *intercept* menuju *neuron* 1 pada *hidden layer* adalah sebesar 0,499 sedangkan pembobot yang menghubungkan *intercept* pada *hidden layer* menuju lapisan *output* sebesar -0,917. Berdasarkan hasil estimasi pembobot yang telah diperoleh, dapat dituliskan persamaan model *neural network* untuk *inflow* pecahan Rp 1.000,00 adalah

$$\hat{Y}_{1,t}^* = -0,917 + 2,463 \tanh(f(x_1)) + 2,0278 \tanh(f(x_2)) \quad (4.8)$$

dengan :

$$Y_t^* = \text{standardized value dari } Y_t ,$$

$$\begin{aligned}
f(x_1) = & 0,499 + 0,008Y_{t-1}^* - 0,017t + 0,498M_1 + 0,592M_2 + 0,499M_3 + \\
& 0,439M_4 + 0,398M_5 + 0,244M_6 + 0,078M_7 + 0,139M_8 + \\
& 0,075M_9 + 0,449M_{10} + 0,702M_{11} + 0,593M_{12} - 0,083V_{1,t} + \quad (4.9) \\
& 0,369V_{2,t} - 0,200V_{3,t} + 0,300V_{4,t} + 0,091V_{1,t+1} + 0,409V_{2,t+1} + \\
& 0,034V_{3,t+1} + 0,213V_{4,t+1},
\end{aligned}$$

$$\begin{aligned}
f(x_2) = & -1,200 + 0,010Y_{t-1}^* + 0,020t + 20,391M_1 + 1,233M_2 + 1,407M_3 + \\
& 1,089M_4 + 1,046M_5 + 1,057M_6 + 1,276M_7 + 1,136M_8 + \\
& 1,234M_9 + 0,779M_{10} + 0,805M_{11} + 1,049M_{12} + 0,218V_{1,t} - \quad (4.10) \\
& 0,830V_{2,t} - 0,279V_{3,t} - 0,884V_{4,t} + 18,477V_{1,t+1} - 0,328V_{2,t+1} + \\
& 18,825V_{3,t+1} + 0,170V_{4,t+1}.
\end{aligned}$$

Perhitungan hasil peramalan satu tahap kedepan dapat diperoleh dengan melakukan perhitungan untuk  $f(x_1)$  dan  $f(x_2)$  terlebih dahulu. Peramalan satu tahap kedepan untuk data *testing* merupakan peramalan untuk bulan Januari 2016, sehingga *dummy* untuk  $M_1$  bernilai 1 sedangkan  $M_2$ - $M_{12}$  bernilai 0. Pada tahun 2016, hari raya Idul Fitri terjadi pada bulan Juli, sehingga *dummy* variasi kalender untuk bulan Januari bernilai 0 untuk keseluruhan *dummy*. *Lag* yang dijadikan *input* untuk pecahan Rp 1000,00 adalah *lag* 1, yakni *inflow* pada bulan Desember 2016 yang bernilai 15,89 miliar. Dengan *mean* dari data sebesar 101,16 miliar dan standar deviasi sebesar 68,99 maka nilai *standardized* dari  $Y_{t-1}$  adalah -1,23. Periode data yang digunakan dimulai dari Januari 2003, maka nilai variabel *dummy* tren untuk bulan Januari 2016 adalah 157. Untuk memudahkan dalam membandingkan hasil peramalan secara manual dengan *output* yang diperoleh, maka dalam perhitungan secara manual akan digunakan hingga 5 desimal dibelakang koma. Berdasarkan *input* yang telah diketahui, dapat diperoleh :

$$\begin{aligned}
f(x_1) &= 0,49935 + 0,00790(-1,23) - 0,01684(157) + 0,49763(1) \\
&= -1,65662, \\
f(x_2) &= -1,20011 + 0,01005(-1,23) + 0,02043(157) + 20,39050(1) \\
&= 22,38000.
\end{aligned}$$



Selanjutnya nilai  $f(x_1)$  dan  $f(x_2)$  disubstitusikan kedalam persamaan (4.8), sehingga diperoleh nilai ramalan dalam *standardized* yakni

$$\begin{aligned}\hat{Y}_{1,156}^* &= -0,917 + 2,463 \tanh(-1,65662) + 2,0278 \tanh(22,38) \\ &= -1,1791.\end{aligned}$$

Setelah diperoleh hasil peramalan satu tahap kedepan, maka akan dikonversikan kembali kedalam satuan awalnya yakni dikalikan dengan standar deviasinya kemudian ditambahkan dengan *mean* sehingga diperoleh hasil ramalan sebesar 19,7731. Nilai tersebut sesuai dengan hasil peramalan pada Lampiran 13 untuk pecahan Rp 1.000,00 pada  $l=1$ .

Dengan cara yang sama, langkah tersebut dilakukan pada 13 pecahan lainnya. Hasil estimasi pembobot model *neural network* untuk 13 pecahan lainnya dapat ditunjukkan pada Lampiran 9. Secara umum, model *neural network* terbaik untuk setiap pecahan ditunjukkan pada Tabel 4.27.

**Tabel 4.27** *Input dan Neuron Optimal untuk Setiap Pecahan*

Pecahan	<i>Input optimal</i>	<i>Neuron optimal</i>
$Y_1$	$Y_{t-1}$	2
$Y_2$	$Y_{t-1}$	3
$Y_3$	$Y_{t-12}$	2
$Y_4$	$Y_{t-12}$	1
$Y_5$	$Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-10}, Y_{t-11}, Y_{t-12}, \text{ dan } Y_{t-13}$	3
$Y_6$	$Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-11}, \text{ dan } Y_{t-12}$	2
$Y_7$	$Y_{t-12}$	3
$Y_8$	$Y_{t-1}, Y_{t-11}, Y_{t-12}, \text{ dan } Y_{t-13}$	2
$Y_9$	$Y_{t-1}, Y_{t-11}, \text{ dan } Y_{t-12}$	3
$Y_{10}$	$Y_{t-1}, Y_{t-11}, \text{ dan } Y_{t-12}$	2
$Y_{11}$	$Y_{t-1}, Y_{t-11}, \text{ dan } Y_{t-12}$	2
$Y_{12}$	$Y_{t-11}, \text{ dan } Y_{t-12}$	1
$Y_{13}$	$Y_{t-11}, \text{ dan } Y_{t-12}$	1
$Y_{14}$	$Y_{t-12}$	5


Tabel 4.27 menunjukkan bahwa terdapat perbedaan *input* dan *neuron* optimal untuk setiap pecahan *inflow* dan *outflow*. Setelah diperoleh model terbaik untuk seluruh pecahan, maka akan dilakukan perbandingan nilai tingkat kesalahan untuk setiap model yang terbentuk yang dapat ditunjukkan oleh Tabel 4.28.


**Tabel 4.28** Perbandingan Kriteria Model *Neural Network* Terbaik untuk Data *Inflow* dan *Outflow*


Data	Pecahan	RMSE	MAE	MdAE	MdAPE	MAPE
<i>Training</i>	$Y_1$	12,52	9,01	6,98	10,37	14,24
	$Y_2$	15,49	10,79	7,79	5,21	12,27
	$Y_3$	59,71	45,77	38,71	9,03	12,09
	$Y_4$	105,48	80,65	65,26	11,31	15,91
	$Y_5$	70,30	52,52	43,21	5,88	7,25
	$Y_6$	1120,39	820,19	602,07	5,92	8,02
	$Y_7$	1178,20	868,53	638,88	7,46	10,45
	$Y_8$	10,21	7,48	5,49	9,79	35,98
	$Y_9$	122,43	51,33	30,66	17,28	30,74
	$Y_{10}$	71,62	50,36	33,56	10,93	17,47
	$Y_{11}$	108,95	75,71	48,20	10,55	21,55
	$Y_{12}$	259,80	202,10	165,34	20,38	33,87
	$Y_{13}$	3509,80	2679,14	1993,79	16,84	29,32
	$Y_{14}$	2041,64	1398,77	905,98	8,62	18,18
<i>Testing</i>	$Y_1$	3,49	3,03	2,57	18,08	21,07
	$Y_2$	22,08	15,86	11,52	3,67	5,76
	$Y_3$	107,33	72,32	46,73	10,24	10,20
	$Y_4$	156,10	86,24	34,20	5,59	9,21
	$Y_5$	101,54	69,16	39,02	5,30	7,73
	$Y_6$	1836,25	1462,93	1236,41	7,62	8,05
	$Y_7$	10805,31	5878,83	2239,52	8,75	18,57
	$Y_8$	3,83	3,30	3,39	128,66	122,43
	$Y_9$	101,73	58,21	12,96	8,14	61,22
	$Y_{10}$	219,54	126,58	74,60	15,80	28,82
	$Y_{11}$	208,01	172,37	116,78	28,12	46,88
	$Y_{12}$	350,74	253,45	151,11	35,03	54,96
	$Y_{13}$	2199,35	1717,43	1347,46	8,12	10,12
	$Y_{14}$	7189,93	5048,30	3044,36	11,14	17,31


Tabel 4.28 menunjukkan bahwa nilai RMSE pecahan yang lebih besar akan cenderung semakin besar. Hal ini dapat dikarenakan perbedaan satuan pecahan yang digunakan. Data untuk pecahan Rp.1000,- memiliki nilai rata-rata Rp 95 miliar, sedangkan data untuk pecahan Rp.100.000,- memiliki rata-rata sebesar Rp 12.549 miliar. Dengan demikian, perbandingan antar pecahan sebaiknya dilakukan menggunakan kriteria yang berbasis persentase, misalnya MAPE dan MdAPE. Berdasarkan nilai MAPE dan MdAPE, dapat diketahui bahwa pecahan *outflow* Rp 1000,00 memiliki kesalahan peramalan paling besar dibandingkan pecahan lainnya. Selanjutnya dilakukan perbandingan data aktual dan ramalan untuk setiap pecahan. Perbandingan dilakukan pada

data *training* dan data *testing* dan dapat ditunjukkan oleh Gambar 4.46.










**Gambar 4.46** Perbandingan Data Aktual dan Ramalan Model *Neural Network* untuk Setiap Pecahan.

Gambar 4.46 menunjukkan bahwa model *neural network* yang terbentuk telah dapat mengikuti pola aktual data *inflow* dan *outflow*. Bahkan pada data *testing*, hanya model *inflow* pecahan Rp 100.000 yang tidak dapat menangkap pola variasi kalender.

#### 4.5 Peramalan *Inflow* dan *Outflow* dengan *Quantile Regression Neural Network*


Pada umumnya, peramalan data *inflow* dan *outflow* menggunakan metode *quantile regression neural network* akan menghasilkan *crossing* antar kuantilnya. Untuk meminimalisir terjadinya *crossing*, maka peramalan menggunakan QRNN dilakukan dengan menggunakan beberapa jenis model QRNN yakni peramalan satu tahap secara langsung, penggunaan dekomposisi sebagai *preprocessing*, penggunaan nilai prediksi *neural network* sebagai *input*, penggunaan nilai prediksi *neural network* dan lag  $Y_t$  dari residual model *neural network*, penggunaan *input* berupa prediksi *time series regression* dan lag  $Y_t$ , serta prediksi *time series regression* dan lag residual *time*

*series regression*. Jenis model QRNN yang dipilih adalah model QRNN yang memiliki *crossing* paling sedikit dengan akurasi peramalan titik yang terbaik. Perbandingan banyaknya *crossing* yang terjadi dapat ditunjukkan oleh Gambar 4.47,




Gambar 4.47 Perbandingan *Crossing* pada Data Training (a) dan Testing (b).

Gambar 4.47 menunjukkan bahwa QRNN satu tahap cenderung akan menghasilkan *crossing* yang lebih banyak pada seluruh pecahan, baik untuk data *training* maupun data *testing*. Sedangkan model QRNN yang cenderung memiliki sedikit *crossing* adalah model QRNN dengan *input* prediksi nilai *neural network*. Namun untuk beberapa pecahan, jenis model QRNN dekomposisi dan *input* berupa *neural network* dan *lag* residual juga menghasilkan *crossing* yang cenderung sedikit pada data *testingnya*. Untuk memudahkan dalam membandingkan keempat jenis model QRNN, maka dilakukan perhitungan rata-rata banyaknya *crossing* untuk seluruh pecahan dan diperoleh perbandingan seperti pada Gambar 4.49.



**Gambar 4.48** Perbandingan Rata-rata Banyaknya *Crossing* untuk Setiap Jenis Model QRNN.


Selanjutnya juga dilakukan perbandingan banyaknya *crossing* untuk setiap *neuron*, seperti pada Gambar 4.49.




**Gambar 4.49** Perbandingan Rata-rata Banyaknya *Crossing* dan *Neuron* untuk Setiap Jenis Model QRNN.



Gambar 4.49 menunjukkan bahwa model QRNN yang memiliki rata-rata *crossing* paling sedikit adalah model QRNN dengan *input* berupa nilai prediksi *neural network*, baik untuk data *training* maupun data *testing*. Model QRNN satu tahap menghasilkan *crossing* paling banyak dibandingkan kelima model lainnya. Hal ini menunjukkan bahwa semakin kompleks model QRNN, maka kemungkinan terjadinya *crossing* akan semakin besar. Pada model QRNN satu tahap banyaknya *input* yang digunakan adalah 21 *input* variabel *dummy* dan beberapa *lag* sebelumnya. Sedangkan dengan *input* prediksi *neural network* hanya menggunakan 1 *input* saja. Selain pengaruh dari *input* yang digunakan, penggunaan banyaknya *neuron* juga mempengaruhi terjadinya *crossing*. Penggunaan *neuron* yang lebih banyak cenderung akan meningkatkan kemungkinan terjadinya *crossing*. Selanjutnya untuk memilih jenis model QRNN juga dilakukan berdasarkan tingkat kesalahan peramalan pada data *testing*. Gambar 4.50 menunjukkan perbandingan nilai RMSE, MdAE, dan MdAE untuk keempat jenis model QRNN.





**Gambar 4.50** Perbandingan Nilai RMSE (a), MdAE (b), dan MdAPE (c) untuk Keenam Model QRNN.

Gambar 4.50 menunjukkan bahwa untuk data *training*, keenam model QRNN cenderung memiliki tingkat kesalahan yang sama berdasarkan kriteria RMSE, MdAE, dan MdAPE. Penambahan *neuron* akan cenderung menghasilkan kesalahan peramalan yang lebih kecil. Sedangkan untuk data *testing*, perbandingan RMSE menunjukkan bahwa keenam jenis model cenderung memiliki akurasi yang sama. Namun, berdasarkan kriteria MdAE dan MdAPE model QRNN dengan *input* berupa nilai prediksi *neural network* menghasilkan rata-rata tingkat kesalahan yang paling kecil untuk semua kombinasi *neuron* yang digunakan. Dengan demikian, peramalan *inflow* dan *outflow* dilakukan dengan menggunakan nilai prediksi *neural network* sebagai *inputnya*.

Nilai kriteria MdAE dan MdAPE pada Gambar 4.50 juga menunjukkan bahwa pada data *testing*, penambahan *neuron* tidak selalu dapat meningkatkan akurasi. Dengan demikian perlu dilakukan *trial and error* dalam menentukan banyaknya *neuron* optimal. Pemilihan *neuron* optimal untuk seluruh pecahan *inflow* dan *outflow* dilakukan berdasarkan tingkat kesalahan peramalan pada data *testing* berdasarkan kriteria RMSE, MAE, MdAE, MdAPE, dan MAPE. Tabel 4.29 menunjukkan nilai tingkat kesalahan untuk seluruh kombinasi *neuron* pada data *inflow* pecahan Rp 1.000,00.

**Tabel 4.29** Perbandingan Kriteria dalam Pemilihan *Neuron Model Quantile Regression Neural Network* untuk Data *Inflow* Pecahan Rp 1.000,00

Neuron	Training					Testing				
	RMSE	MAE	MdAE	MdAPE	MAPE	RMSE	MAE	MdAE	MdAPE	MAPE
1	12,55	8,98	6,58	10,89	13,94	<b>3,21</b>	<b>2,44</b>	<b>1,26</b>	<b>8,63</b>	<b>16,61</b>
2	12,54	8,85	6,46	10,03	13,65	3,36	2,99	2,60	19,10	21,21
3	12,54	8,84	6,24	10,09	13,56	3,35	3,01	2,66	19,03	21,52
4	12,40	8,58	5,36	9,15	13,03	3,37	3,05	2,77	16,76	22,79
5	12,38	8,44	5,22	9,13	12,93	4,74	3,99	3,62	24,14	31,45
10	12,85	8,20	4,99	9,67	12,76	4,71	4,00	3,70	24,97	31,38
15	12,23	8,31	5,73	8,50	12,76	5,17	4,13	3,41	23,03	33,05

Keterangan : angka yang dicetak tebal merupakan nilai minimum untuk setiap kriteria

Pada pecahan Rp 1.000,00, *neuron* optimal dalam pemodelan QRNN adalah sebanyak 1. Hal ini dapat diketahui dari nilai kesalahan terkecil berdasarkan kriteria RMSE, MAE, MdAE, MdAPE, dan MAPE pada data *testing*, seperti ditunjukkan pada Tabel 4.29. Hasil estimasi parameter model QRNN untuk *inflow* pecahan Rp 1.000,00 dengan *neuron* sebanyak 1 dapat ditunjukkan pada Tabel 4.30.

**Tabel 4.30** Estimasi Parameter Model QRNN untuk *Inflow* Pecahan Rp 1.000,00

Prediktor		Hidden Layer			Output Layer		
		$\tau=0,025$	$\tau=0,5$	$\tau=0,975$	$\tau=0,025$	$\tau=0,5$	$\tau=0,975$
Input layer	Intercept	-0,167	-0,043	1,931			
	$\hat{Z}_t$	-0,001	0,011	0,248			
Hidden layer	Intercept				-118,123	3,782	-14,779
	Neuron				-1415,488	174,742	20,483

Hasil estimasi parameter untuk pembobot QRNN dapat dituliskan kedalam persamaan:

$$Y_{1,t}^*(0,025) = -118,123 - 1415,49 \tanh(0,5 \times (-0,167 - 0,001\hat{Z}_t)) \quad (4.11)$$

$$Y_{1,t}^*(0,5) = 3,782 - 174,742 \tanh(0,5 \times (-0,043 - 0,011\hat{Z}_t)) \quad (4.12)$$

$$Y_{1,t}^*(0,975) = -14,779 - 20,483 \tanh(0,5 \times (1,931 - 0,248\hat{Z}_t)) \quad (4.13)$$

dengan  $\hat{Z}_t$  merupakan nilai prediksi *inflow* pecahan Rp 1.000,00 menggunakan metode *neural network* seperti pada persamaan (4.8). Perhitungan nilai ramalan metode QRNN dapat dilakukan dengan cara yang sama seperti pada peramalan menggunakan

*neural network*, namun *input* yang digunakan oleh model QRNN merupakan hasil prediksi dari metode *neural network*. Pada model QRNN, kuantil 0,025 akan digunakan sebagai batas bawah peramalan, kuantil 0,5 sebagai hasil peramalan titik, dan kuantil 0,975 sebagai batas atas peramalan sehingga akan terbentuk prediksi interval untuk peramalan *inflow* dan *outflow*. Untuk kuantil 0,025 perhitungan ramalan periode Januari 2016 dapat dilakukan menggunakan persamaan (4.11). Nilai prediksi dari metode *neural network* untuk  $l=1$  adalah 19,7635 (dari Lampiran 13). Dengan *mean* untuk variabel independen adalah 94,92117 dan standar deviasi sebesar 65,02181 akan diperoleh nilai *standardized* untuk variabel independen sebesar -1,15588. Nilai tersebut akan disubstitusikan kedalam persamaan 4.11 sehingga diperoleh:

$$\begin{aligned} Y_{1,156}^* (1) &= -118,1228 - 1415,4881 \tanh(0,5 \times (-0,16683 - 0,00133(-1,15588))) \\ &= -118,1228 - 1415,4881 \tanh(-0,08236) \\ &= 1,40165. \end{aligned}$$


Setelah diperoleh hasil ramalan dalam *standardized*, maka hasil ramalan tersebut akan dikonversikan kembali menggunakan mean dan standar deviasi dari variabel dependen, yakni sebesar 94,8489 dan 66,24,173 sehingga diperoleh nilai ramalan sebesar Rp 2,0011 miliar, sesuai dengan hasil ramalan pada Lampiran 13 untuk metode QRNN *inflow* pecahan Rp 1.000,00 yakni sebesar 2,0601 miliar. Selisih hasil ramalan yang diperoleh dapat disebabkan oleh pembulatan hasil estimasi parameter yang dilakukan.


Selanjutnya analisis yang sama juga dilakukan pada 13 pecahan lainnya. Setelah diperoleh peramalan untuk data *testing*, akan dilakukan perhitungan kriteria tingkat kesalahan peramalan untuk tiap pecahan. Secara lengkap, nilai kriteria untuk 13 pecahan lainnya dapat dilihat pada Lampiran 12, sedangkan hasil estimasi parameter model QRNN dapat dilihat pada Lampiran 11. Secara umum, Tabel 4.31 menunjukkan banyaknya *neuron* optimal beserta tingkat kesalahan peramalan data *testing* tiap pecahan.


**Tabel 4.31** Perbandingan Kriteria Model *Quantile Regression Neural Network* untuk Data *Inflow* dan *Outflow*

Data	Pecahan	Neuron	RMSE	MAE	MdAE	MdAPE	MAPE
<i>Training</i>	$Y_1$	1	12,55	8,98	6,58	10,89	13,94
	$Y_2$	15	15,28	10,37	6,93	4,64	10,84
	$Y_3$	10	52,16	38,26	29,92	8,57	10,39
	$Y_4$	5	103,28	76,66	60,96	12,18	15,15
	$Y_5$	1	70,45	52,35	43,70	6,11	7,16
	$Y_6$	2	1086,93	758,99	508,93	4,80	7,42
	$Y_7$	10	1139,48	819,74	601,54	6,18	9,28
	$Y_8$	5	9,33	6,46	4,19	9,80	25,11
	$Y_9$	3	99,06	36,42	21,68	14,23	20,04
	$Y_{10}$	1	71,61	50,32	33,30	11,00	17,38
	$Y_{11}$	15	109,89	72,50	39,35	9,20	20,45
	$Y_{12}$	1	263,22	197,53	152,63	21,42	31,95
	$Y_{13}$	4	3434,80	2403,92	1492,82	12,91	27,06
	$Y_{14}$	4	2041,63	1383,04	895,27	7,66	17,98
<i>Testing</i>	$Y_1$	1	3,21	2,44	1,26	8,63	16,61
	$Y_2$	15	23,51	15,61	8,84	3,10	5,68
	$Y_3$	10	99,01	64,09	38,21	8,65	10,78
	$Y_4$	5	161,86	85,58	34,35	5,90	8,50
	$Y_5$	1	103,76	70,42	41,00	5,68	7,90
	$Y_6$	2	1667,78	1263,03	963,65	5,80	6,95
	$Y_7$	10	10673,51	5887,65	2506,22	9,78	18,51
	$Y_8$	5	2,14	1,69	1,28	48,03	57,69
	$Y_9$	3	101,25	56,98	8,46	8,89	60,16
	$Y_{10}$	1	218,93	126,43	73,56	15,80	28,66
	$Y_{11}$	15	203,33	159,04	98,81	25,95	45,37
	$Y_{12}$	1	436,55	324,19	188,56	37,06	55,56
	$Y_{13}$	4	2266,39	1567,00	895,30	6,22	8,61
	$Y_{14}$	4	7132,38	4981,52	2904,52	11,15	17,09


Berdasarkan Tabel 4.31, dapat diketahui bahwa berdasarkan nilai MAPE dan MdAPE masih terdapat beberapa pecahan yang memiliki persentase tingkat kesalahan tinggi mencapai lebih dari 50%, yakni pecahan *outflow* Rp 1.000,00; Rp 2.000,00; dan Rp 20.000,00. Sedangkan pecahan *inflow* Rp 2.000,00 merupakan pecahan yang memiliki persentase kesalahan paling kecil dibandingkan pecahan lainnya. Selanjutnya, dilakukan perbandingan data aktual dan ramalan untuk data *training* dan *testing* setiap pecahan yang dapat ditunjukkan oleh Gambar 4.51.











**Gambar 4.51.** Perbandingan Data Aktual dan Ramalan Model *Quantile Regression Neural Network* untuk Setiap Pecahan.

Gambar 4.51 menunjukkan bahwa hasil ramalan dapat mengikuti pola data aktual, baik untuk data *training* maupun data *testing*. Pada data *testing*, hanya model pecahan *inflow* Rp 100.000,00 yang kurang dapat menangkap pola variasi kalender. Hal ini dapat disebabkan oleh peningkatan *inflow* yang lebih tajam pada hari raya Idul Fitri di tahun 2016 dibandingkan tahun-tahun sebelumnya untuk hari raya Idul Fitri yang terjadi pada minggu pertama.

Pada dasarnya, peramalan interval yang terbentuk dari model QRNN dapat memuat sebagian besar data *testing*. Selain itu interval yang dihasilkan juga cenderung jauh lebih sempit dibandingkan dengan peramalan interval pada model ARIMAX. Namun adanya *crossing* pada beberapa titik mengakibatkan peramalan *interval* yang terbentuk kurang *valid*. Dengan demikian, perbandingan hasil peramalan interval tidak dapat dilakukan.

#### 4.6 Perbandingan kebaikan model ARIMAX, Neural Network, dan Quantile Regression Neural Network

Setelah diperoleh model terbaik untuk setiap metode pada setiap pecahan, maka dilakukan perbandingan untuk ketiga metode yang digunakan. Selanjutnya dipilih satu metode terbaik berdasarkan kesalahan peramalan terkecil pada data *testing*. Perbandingan ketiga metode ditunjukkan pada Tabel 4.32.

**Tabel 4.32** Perbandingan Model ARIMAX, Neural Network, dan Quantile Regression Neural Network untuk Data Inflow dan Outflow


Pecahan	Metode	RMSE	MAE	MdAE	MdAPE	MAPE
$Y_1$	ARIMAX	15,89	12,42	8,36	71,87	82,76
	NN	3,49	3,03	2,57	18,08	21,07
	<b>QRNN</b>	<b>3,21</b>	<b>2,44</b>	<b>1,26</b>	<b>8,63</b>	<b>16,61</b>
$Y_2$	ARIMAX	83,03	77,74	70,34	26,03	31,58
	NN	<b>22,08</b>	15,86	11,52	3,67	5,76
	<b>QRNN</b>	23,51	<b>15,61</b>	<b>8,84</b>	<b>3,10</b>	<b>5,68</b>
$Y_3$	ARIMAX	117,27	78,88	57,02	12,72	12,90
	NN	107,33	72,32	46,73	10,24	<b>10,20</b>
	<b>QRNN</b>	<b>99,01</b>	<b>64,09</b>	<b>38,21</b>	<b>8,65</b>	10,78
$Y_4$	ARIMAX	223,45	122,89	43,05	7,36	11,71
	NN	<b>156,10</b>	86,24	<b>34,20</b>	<b>5,59</b>	9,21
	QRNN	161,86	<b>85,58</b>	34,35	5,90	<b>8,50</b>
$Y_5$	ARIMAX	352,98	242,40	139,42	18,03	22,53
	NN	<b>101,54</b>	<b>69,16</b>	<b>39,02</b>	<b>5,30</b>	<b>7,73</b>
	QRNN	103,76	70,42	41,00	5,68	7,90
$Y_6$	ARIMAX	3767,76	2667,62	1548,66	11,85	12,62
	NN	1836,25	1462,93	1236,41	7,62	8,05
	<b>QRNN</b>	<b>1667,78</b>	<b>1263,03</b>	<b>963,65</b>	<b>5,80</b>	<b>6,95</b>
$Y_7$	ARIMAX	11887,99	7445,63	3923,95	17,31	20,93
	NN	10805,31	<b>5878,83</b>	<b>2239,52</b>	<b>8,75</b>	18,57
	<b>QRNN</b>	<b>10673,51</b>	5887,65	2506,22	9,78	<b>18,51</b>
$Y_8$	ARIMAX	87,84	47,02	22,70	873,22	1166,80
	NN	3,83	3,30	3,39	128,66	122,43
	<b>QRNN</b>	<b>2,14</b>	<b>1,69</b>	<b>1,28</b>	<b>48,03</b>	<b>57,69</b>
$Y_9$	ARIMAX	438,31	206,03	69,11	52,48	80,48
	NN	101,73	58,21	12,96	<b>8,14</b>	61,22
	<b>QRNN</b>	<b>101,25</b>	<b>56,98</b>	<b>8,46</b>	8,89	<b>60,16</b>
$Y_{10}$	ARIMAX	539,42	325,66	118,18	39,00	91,81
	NN	219,54	126,58	74,60	15,80	28,82
	<b>QRNN</b>	<b>218,93</b>	<b>126,43</b>	<b>73,56</b>	<b>15,80</b>	<b>28,66</b>


**Tabel 4.32** Perbandingan Model ARIMAX, *Neural Network*, dan *Quantile Regression Neural Network* untuk Data *Inflow* dan *Outflow* (Lanjutan)


Pecahan	Metode	RMSE	MAE	MdAE	MdAPE	MAPE
$Y_{11}$	ARIMAX	736,00	434,00	174,86	39,57	94,90
	NN	208,01	172,37	116,78	28,12	46,88
	<b>QRNN</b>	<b>203,33</b>	<b>159,04</b>	<b>98,81</b>	<b>25,95</b>	<b>45,37</b>
$Y_{12}$	ARIMAX	772,42	480,62	260,78	39,07	73,35
	<b>NN</b>	<b>350,74</b>	<b>253,45</b>	<b>151,11</b>	<b>35,03</b>	<b>54,96</b>
	QRNN	436,55	324,19	188,56	37,06	55,56
$Y_{13}$	ARIMAX	2925,16	2569,97	2461,70	14,14	16,83
	<b>NN</b>	<b>2199,35</b>	1717,43	1347,46	8,12	10,12
	<b>QRNN</b>	2266,39	<b>1567,00</b>	<b>895,30</b>	<b>6,22</b>	<b>8,61</b>
$Y_{14}$	ARIMAX	12615,51	7821,79	3797,41	14,43	28,38
	NN	7189,93	5048,30	3044,36	<b>11,14</b>	17,31
	<b>QRNN</b>	<b>7132,38</b>	<b>4981,52</b>	<b>2904,52</b>	11,15	<b>17,09</b>

Keterangan : angka yang dicetak tebal merupakan nilai minimum untuk setiap kriteria untuk setiap data.

Tabel 4.32 menunjukkan bahwa metode terbaik untuk meramalkan *inflow* dan *outflow* dapat berbeda untuk setiap pecahan. Metode NN merupakan metode yang lebih baik dibandingkan ARIMAX dan QRNN untuk pecahan  $Y_4$ ,  $Y_5$ ,  $Y_7$ , dan  $Y_{12}$ . Sedangkan pada 10 pecahan lainnya, metode QRNN memiliki tingkat kesalahan lebih kecil dibandingkan metode NN dan ARIMAX. Kemudian, perbandingan data hasil ramalan dengan data *testing* untuk periode 2016 dapat divisualisasikan kedalam Gambar 4.52.








**Gambar 4.52** Perbandingan Data Aktual-Ramalan untuk Metode ARIMAX, NN, dan QRNN.

Gambar 4.52 menunjukkan bahwa untuk beberapa pecahan, hasil peramalan metode NN dan QRNN tidak jauh berbeda. Dengan demikian, dalam memilih model terbaik juga perlu dilakukan analisis tingkat kesalahan yang tereduksi apabila menggunakan metode NN dan QRNN dibandingkan dengan tingkat kesalahan metode ARIMAX. Berdasarkan Tabel 4.32 dapat diketahui bahwa kriteria yang paling stabil adalah kriteria MdAE. Metode terbaik yang terpilih memiliki kriteria MdAE terkecil untuk seluruh pecahan. Dengan demikian, kriteria MdAE akan digunakan untuk mengetahui besarnya tingkat kesalahan metode ARIMAX yang tereduksi apabila menggunakan metode NN dan QRNN. Jika rasio MdAE bernilai kurang dari 1 maka metode tersebut lebih baik dibandingkan ARIMAX. Perbandingan ketiga metode dapat ditunjukkan oleh Tabel 4.33.

**Tabel 4.33** Perbandingan Rasio MdAE NN dan QRNN terhadap MdAE ARIMAX


Pecahan	Rasio terhadap MdAE ARIMAX		Pecahan	Rasio terhadap MdAE ARIMAX	
	NN	QRNN		NN	QRNN
$Y_1$	0,307	<b>0,151</b>	$Y_8$	0,149	<b>0,057</b>
$Y_2$	0,164	<b>0,126</b>	$Y_9$	0,187	<b>0,122</b>
$Y_3$	0,820	<b>0,670</b>	$Y_{10}$	0,631	<b>0,622</b>
$Y_4$	<b>0,794</b>	0,798	$Y_{11}$	0,668	<b>0,565</b>
$Y_5$	<b>0,280</b>	0,294	$Y_{12}$	<b>0,579</b>	0,723
$Y_6$	0,798	<b>0,622</b>	$Y_{13}$	0,547	<b>0,364</b>
$Y_7$	<b>0,571</b>	0,639	$Y_{14}$	0,802	<b>0,765</b>

Untuk memudahkan dalam melakukan perbandingan, Tabel 4.33 juga dapat diilustrasikan kedalam Gambar 4.53.



**Gambar 4.53** Perbandingan Rasio MdAE NN dan QRNN terhadap MdAE ARIMAX

Tabel 4.33 menunjukkan bahwa metode NN dan QRNN lebih baik apabila dibandingkan dengan ARIMAX untuk semua pecahan. Hal ini ditandai oleh rasio yang lebih dari 1 untuk kedua metode pada seluruh pecahan. Kemudian, apabila dilakukan perbandingan MdAE yang tereduksi, pada pecahan *inflow* Rp 10.000,00 ( $Y_4$ ) dan Rp 20.000,00 ( $Y_5$ ), kemampuan model NN dan QRNN dalam mereduksi tingkat kesalahan model ARIMAX tidak berbeda secara signifikan. Pada pecahan *inflow* Rp 10.000,00 model NN dapat mereduksi MdAE model ARIMAX sebesar 20,6%, sedangkan model QRNN dapat mereduksi model ARIMAX sebesar 20,2%. Frekuensi metode terbaik untuk setiap pecahan dapat diilustrasikan kedalam Gambar 4.54.



**Gambar 4.54** Perbandingan Model ARIMAX, *neural network*, dan *Quantile Regression Neural Network* untuk Data *Inflow* Dan *Outflow*.


Gambar 4.54 menunjukkan bahwa metode QRNN terbaik dalam meramalkan 10 pecahan yang digunakan. Sedangkan metode *neural network* terbaik dalam meramalkan 4 pecahan. Dengan demikian, metode terbaik untuk meramalkan *inflow* dan *outflow* dapat berbeda untuk setiap pecahan. Metode yang digunakan harus disesuaikan dengan karakteristik data yang tersedia. Apabila metode terbaik yang terpilih dikaitkan dengan karakteristik data *inflow* dan *outflow*, maka diperoleh

**Tabel 4.34** Karakteristik data *inflow* dan *outflow* beserta metode terbaiknya


Pecahan	Input optimal	Neuron	Hasil uji Linieritas	Heteroskedastisitas	Heteroskedastisitas musiman	Metode terbaik
$Y_1$	$Y_{t-1}$	2	Nonlinier	Ya	Ya	QRNN
$Y_2$	$Y_{t-1}$	3	Nonlinier	Ya	Ya	QRNN
$Y_3$	$Y_{t-12}$	2	Nonlinier	Ya	Ya	QRNN
$Y_4$	$Y_{t-12}$	1	Nonlinier	Ya	Ya	NN
$Y_5$	$Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-10}, Y_{t-11}, Y_{t-12},$ dan $Y_{t-13}$	3	Nonlinier	Ya	Ya	NN
$Y_6$	$Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-11},$ dan $Y_{t-12}$	2	Nonlinier	Ya	Ya	QRNN
$Y_7$	$Y_{t-12}$	3	Nonlinier	Ya	Ya	NN
$Y_8$	$Y_{t-1}, Y_{t-11}, Y_{t-12},$ dan $Y_{t-13}$	2	Nonlinier	Ya	Ya	QRNN
$Y_9$	$Y_{t-1}, Y_{t-11},$ dan $Y_{t-12}$	3	Nonlinier	Ya	Ya	QRNN
$Y_{10}$	$Y_{t-1}, Y_{t-11},$ dan $Y_{t-12}$	2	Nonlinier	Ya	Ya	QRNN
$Y_{11}$	$Y_{t-1}, Y_{t-11},$ dan $Y_{t-12}$	2	Nonlinier	Ya	Ya	QRNN
$Y_{12}$	$Y_{t-11},$ dan $Y_{t-12}$	1	Linier	Ya	Ya	NN
$Y_{13}$	$Y_{t-11},$ dan $Y_{t-12}$	1	Linier	Ya	Ya	QRNN
$Y_{14}$	$Y_{t-12}$	5	Linier	Ya	Ya	QRNN


#### 4.7 Peramalan Data *Inflow* dan *Outflow* Tahun 2017


Peramalan *inflow* dan *outflow* periode tahun 2017 dilakukan menggunakan metode terbaik yang telah diperoleh. Dengan demikian, metode yang digunakan untuk meramalkan *inflow* dan *outflow* akan berbeda untuk setiap pecahannya. Berdasarkan metode terbaik seperti pada Tabel 4.32, hasil peramalan *inflow* dan *outflow* untuk periode tahun 2017 dapat dilihat pada Lampiran 13, dan dapat divisualisasikan kedalam Gambar 4.55.











**Gambar 4.55** Hasil Peramalan *Inflow* dan *Outflow* untuk Periode Tahun 2017 (Miliar Rp).

Berdasarkan Gambar 4.55, *inflow* tertinggi pada sebagian besar pecahan terjadi pada bulan Juli, hanya pada *inflow* pecahan Rp 10.000 yang hasil peramalan untuk setiap bulannya cenderung sama. Sedangkan enam pecahan lainnya memiliki nilai yang tinggi pada bulan Juli. Hal ini dapat disebabkan oleh kejadian Idul Fitri pada tahun 2017 yang terjadi pada bulan Juni minggu keempat.

Gambar 4.55 juga menunjukkan bahwa pada tahun 2017, *outflow* tertinggi untuk seluruh pecahan terjadi pada bulan Juni.

Hal ini juga telah sesuai dengan pola variasi kalender yakni hari raya Idul Fitri yang terjadi pada minggu ke 4 bulan Juni akan mengakibatkan *outflow* yang tinggi pada bulan Juni dan satu bulan sebelumnya.

## BAB V

### KESIMPULAN DAN SARAN

#### 5.1 Kesimpulan

Berdasarkan analisis yang telah dilakukan, diperoleh kesimpulan sebagai berikut.

1. Perbandingan akurasi pada studi simulasi menunjukkan bahwa metode *quantile regression neural network* mampu menangkap pola heteroskedastisitas dan nonlinieritas. Sedangkan pada data yang tidak mengandung pola heteroskedastisitas dan nonlinieritas, metode QRNN juga dapat menghasilkan hasil peramalan yang lebih baik dibandingkan metode ARIMAX dan *neural network*.
2. Data *inflow* dan *outflow* di Indonesia memiliki kemiringan ke kanan untuk setiap pecahan yang dapat disebabkan oleh tingginya nilai *inflow* dan *outflow* pada waktu-waktu tertentu, yakni pada periode sekitar hari raya Idul Fitri. Hari raya Idul Fitri yang terjadi pada minggu yang berbeda akan mengakibatkan perbedaan peningkatan *inflow* dan *outflow*. Berdasarkan identifikasi menggunakan *boxplot*, dapat diketahui bahwa data *inflow* dan *outflow* memiliki pola heteroskedastisitas musiman.
3. Peramalan menggunakan metode ARIMAX menunjukkan bahwa untuk data *training*, hasil ramalan cenderung dapat mengikuti pola data aktual dengan baik. Namun, untuk data *testing*, pada beberapa pecahan, masih terdapat model yang tidak dapat menangkap pola variasi kalender dengan baik, yakni *inflow* pada pecahan Rp 20.000,00 dan Rp 100.000,00 serta *outflow* Rp 2.000,- dan Rp 100.000,-.
4. Dalam peramalan menggunakan *neural network*, salah satu komponen penting yang dapat memengaruhi akurasi peramalan adalah pemilihan *input* yang digunakan. Pemilihan *input* dapat dilakukan berdasarkan *lag* signifikan pada plot PACF data yang telah stasioner. Model *neural network* yang

terbentuk telah dapat mengikuti pola aktual data *inflow* dan *outflow*, baik untuk data *training* maupun data *testing*. Bahkan pada data *testing*, hanya model *inflow* pecahan Rp 100.000 yang tidak dapat menangkap pola variasi kalender.

5. Peramalan menggunakan *quantile regression neural network* menunjukkan bahwa data ramalan dapat mengikuti pola data aktual, baik untuk data *training* maupun data *testing*. Pada data *testing*, hanya model pecahan *inflow* Rp 50.000,00 yang kurang dapat menangkap pola variasi kalender. Pada dasarnya peramalan interval yang terbentuk juga dapat memuat sebagian besar data *testing* dan intervalnya cenderung jauh lebih sempit dibandingkan dengan peramalan interval model ARIMAX. Namun adanya *crossing* pada beberapa titik mengakibatkan peramalan *interval* yang terbentuk menjadi kurang *valid*.
6. Perbandingan metode ARIMAX, *neural network* dan *quantile regression neural network* menunjukkan bahwa *quantile regression neural network* merupakan metode terbaik dalam meramalkan 10 pecahan dari 14 pecahan, dan metode *neural network* terbaik untuk 4 pecahan lainnya.
7. Hasil peramalan untuk periode 2017 menunjukkan bahwa *inflow* tertinggi pada sebagian besar pecahan terjadi pada bulan Juli, hanya pada *inflow* pecahan Rp 10.000 yang hasil peramalan untuk setiap bulannya cenderung sama. Sedangkan *outflow* tertinggi untuk seluruh pecahan terjadi pada bulan Juni. Hal ini juga telah sesuai dengan pola variasi kalender yakni hari raya Idul Fitri yang terjadi pada minggu ke 4 bulan Juni.

## 5.2 Saran

Berdasarkan kesimpulan yang diperoleh, dapat dirumuskan saran sebagai berikut.

1. Pada metode *quantile regression neural network*, peramalan interval yang terbentuk tidak *valid*. Hal ini dapat disebabkan oleh pengestimasiian setiap kuantil yang dilakukan secara

independen. Hal ini mengakibatkan ketidaksesuaian dengan karakteristik fungsi cdf yang selalu meningkat. Untuk memperoleh batas atas dan batas bawah yang memenuhi sifat cdf yang selalu meningkat, perlu dilakukan penelitian lanjutan dengan menggunakan regresi kuantil *bootstrap*, metode *rearrangement*, maupun penggunaan parameter regularisasi.

2. Pada penelitian ini, pemilihan *input* untuk metode *quantile regression neural network* dilakukan berdasarkan *lag* dari data yang dianalisis, prediksi nilai *neural network*, dan penggunaan *preprocessing* berupa dekomposisi. Penelitian lanjutan dengan menggunakan *input* berupa hasil prediksi dari metode nonlinier lainnya juga perlu dilakukan untuk mengetahui *input* terbaik dalam pemodelan menggunakan metode *quantile regression neural network*.
3. Penelitian lanjutan juga perlu dilakukan untuk membandingkan metode *quantile regression neural network* dengan metode *nonlinear quantile regression* yang lain untuk mengetahui kelebihan dan kekurangan metode-metode nonlinier tersebut.

*(Halaman ini sengaja dikosongkan)*



## DAFTAR PUSTAKA

- Ahmad, I. S., Setiawan, Suhartono, & Masun, N. H. (2015). Forecasting of Monthly Inflow and Outflow Currency using Time Series Regression and ARIMAX: The Idul Fitri Effect. *American Institute of Physics*, 1691, 050002.
- Andani, F. P., & Widodo, E. (2016). Perbandingan Kemampuan Regresi Kuantil Median dan Transformasi Box-Cox dalam Menangani Heteroskedastisitas. *Konferensi Nasional Penelitian Matematika dan Pembelajarannya*, 934-941.
- Anders, U., & Korn, O. (1999). Model selection in neural networks. *Neural Networks*, 309–323.
- Apriliadara, M., Suhartono, & Prastyo, D. D. (2016). VARI-X model for currency inflow and outflow forecasting with Eid Fitr effect in Indonesia. *AIP Conference Proceedings*, 1746, 020041.
- Armstrong, S., & Collopy, F. (1992). Error Measures for Generalizing About Forecasting Methods: Empirical Comparisons. *International Journal of Forecasting*, 69-80.
- Arunraj, N. S., & Ahrens, D. (2015). A Hybrid Seasonal Autoregressive Integrated Moving Average and Quantile Regression for Daily Food Sales Forecasting. *International Journal Production Economics*, 321–335.
- Bank Indonesia. (2001). *Peraturan Bank Indonesia Nomor: 3/17/PBI/2001 Tentang Laporan Berkala Bank Umum*. Jakarta: Bank Indonesia.
- Bank Indonesia. (2010). *Sistem Pembayaran dan Pengedaran Uang Tahun 2010*. Jakarta: Bank Indonesia.
- Bank Indonesia. (2012). *Sistem Pembayaran dan Pengedaran Uang Tahun 2012*. Jakarta: Bank Indonesia.
- Bondell, H. D., Reich, B. J., & Wang, H. (2010). Non-crossing Quantile Regression Curve Estimation. *Biometrika*, 1-13.
- Bowerman, B., & O'Connell, R. (1993). *Forecasting and Time Series* (3rd ed.). California: Duxbury Press.

- Box, G., & Cox, D. R. (1964). An Analysis of Transformations. *Journal of The Royal Statistical Society*, 211-252.
- Cannon, A. J. (2011). Quantile regression neural networks: Implementation in R and application to precipitation downscaling. *Computers & Geosciences*, 1277-1284.
- Crone, S. F., & Kourentzes, N. (2009). Input-variable Specification for Neural Networks - an Analysis of Forecasting low and high Time Series Frequency. *International Joint Conference on Neural Networks*, 14-19.
- Cryer, J. D., & Chan, K. S. (2008). *Time Series Analysis with Applications in R*. New York: Springer Science.
- Daniel, W. W. (1989). *Statistik Nonparametrik Terapan*. (Penerjemah: Widodo, A.T). Jakarta: PT. Gramedia.
- Departemen Statistik Bank Indonesia. (2016). *Uang Kartal yang Diedarkan (UYD)*. Jakarta: Bank Indonesia.
- Faraway, J., & Chatfield, C. (1998). Time Series Forecasting with Neural Networks: A Comparative Study Using the Airline Data. *Applied Statistics*, 231-250.
- Feng, Y., Li, R., Sudjianto, A., & Zhang, Y. (2010). Robust Neural Network with Applications to Credit Portfolio Data Analysis. *Statistics and its Interface*, 437-444.
- Goldameir, N. E. (2015). *Pemodelan Statistical Downscaling dengan Regresi Kuantil Spline Untuk Prediksi Curah Hujan Ekstrem di Kabupaten Indramayu*. Bogor: IPB.
- Gooijer, J. G., & Hyndman, R. J. (2006). 25 years of time series forecasting. *International Journal of Forecasting*, 443-473.
- Guerard, J. B. (2013). *Introduction to Financial Forecasting in Investment Analysis*. New York: Springer.
- Gujarati, D. N. (2004). *Basic Econometrics* (4th ed.). New York: The McGraw-Hill.

- Guler, H., & Talasli, A. (2010). Modelling the Daily Currency in Circulation in Turkey. *Central Bank of the Republic of Turkey*, 29-46.
- Hamilton, J. D. (1994). *Time Series Analysis*. New Jersey: Princeton University Press.
- He, Y., Xu, Q., Wan, J., & Yang, S. (2016). Short-Term Power Load Probability Density Forecasting Based on Quantile Regression Neural Network and Triangle Kernel Function. *Energy*, 498-512.
- Hlavacek, M., Kalous, R., & Hakl, F. (2009). Neural Network with Cooperative Switching Units with Application to Time Series Forecasting. *Computer Science and Information Engineering*, 676-682.
- Ikoku, A. (2014). Modeling and Forecasting Currency in Circulation for Liquidity Management in Nigeria. *Journal of Applied Statistics*, 79-104.
- Joseph, A., Larrain, M., & Ottoo, R. (2013). Comparing the Forecasts of Money Demand. *Procedia Computer Science*, 478-483.
- Koenker, R. (2005). *Quantile Regression*. United States of Amerika: Cambridge University Press.
- Kozinski, W., & Swist, T. (2015). Short-Term Currency in Circulation Forecasting for Monetary Policy Purposes – The Case of Poland. *Financial Internet Quarterly*, 65-75.
- Lee, M. H., Suhartono, & Hamzah, N. A. (2010). Calendar variation model based on ARIMAX for forecasting sales data with Ramadhan effect. *Regional Conference on Statistical Sciences*, 349-361.
- Makridakis, S., & Hibon, M. (2000). The M3-Competition: Results, Conclusions and Implications. *International Journal of Forecasting*, 451-476.
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1998). *Forecasting: Methods and Applications* (3rd Edition ed.). USA: Wiley.

- Nasiru, S., Luguterah, A., & Anzagra, L. (2013). The Efficacy of ARIMAX and SARIMA Models in Predicting Monthly Currency in Circulation in Ghana. *Mathematical Theory and Modeling*, 73-81.
- Rachmawati, N. I., Setiawan, & Suhartono. (2015). Peramalan Inflow dan Outflow Uang Kartal Bank Indonesia di Wilayah Jawa Tengah dengan Menggunakan Metode ARIMA, Time Series Regression, dan ARIMAX. *Jurnal Sains dan Seni ITS*, 2337-3520.
- Sarle, W. S. (1994). Neural Networks and Statistical Models. *Proceedings of the Nineteenth Annual SAS Users Group International Conference* (hal. 1538-1550). USA: SAS Institute.
- Setiawan, Suhartono, Ahmad, I. S., & Rahmawati, N. I. (2015). Configuring Calendar Variation based on Time Series Regression Method for Forecasting of Monthly Currency Inflow and Outflow in Central Java. *American Institute of Physics*, 1691, 050024.
- Sigalingging, H., Setiawan, E., & Sihaloho, H. D. (2004). *Kebijakan Pengedaran Uang di Indonesia*. Jakarta: Pusat Pendidikan dan Studi Kebanksentralan (PPSK).
- Solikin, & Suseno. (2002). *Pengertian, Penciptaan dan Peranan Uang dalam Perekonomian*. Jakarta: Pusat Pendidikan dan Studi Kebanksentralan (PPSK).
- Suhartono. (2007). *Feedforward Neural Network untuk Pemodelan Runtun Waktu*. Yogyakarta: Disertasi Doktoral, Universitas Gajah Mada.
- Suhartono, & Subanar. (2006). The Effect of Decomposition Method as Data Preprocessing on Neural Networks Model for Forecasting Trend and Seasonal Time Series. *Jurnal Keilmuan dan Aplikasi Teknik Industri*, 27-41.
- Suhartono, Lee, M. H., & Prastyo, D. D. (2015). Two Levels ARIMAX and Regression Models for Forecasting Time

- Series Data with Calendar variations Effects. *AIP Conference Proceedings*, 1691, 050026.
- Taylor, J. W. (2000). A Quantile Regression Neural Network Approach to Estimating the Conditional Density of Multiperiod Returns. *Journal of Forecasting*, 299-311.
- Telbany, M. E. (2014). What Quantile Regression Neural Networks Tell us About Prediction of Drug Activities. *10th International Computer Engineering Conference*, 76-80.
- Wei, W. W. (2006). *Time Series Analysis Univariate and Multivariate Methods* (2nd ed.). United States of America: Pearson Education, Inc.
- Wong, C. M. (2016). A Quantile Regression Approach to the Multiple Period Value at Risk Estimation. *Journal of Economics and Management*, 1-35.
- Yeh, I. C. (2014). Estimating Distribution of Concrete Strength Using Quantile Regression Neural Networks. *Applied Mechanics and Materials*, 1017-1025.
- Zhang, G. P. (2003). Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*, 159-175.
- Zhang, G. P., & Qi, M. (2005). Neural network forecasting for seasonal and trend time series. *European Journal of Operational Research*, 501-514.


*(Halaman ini sengaja dikosongkan)*

## LAMPIRAN


### Lampiran 1 Data *Inflow* dan *Outflow* di Indonesia

<i>Inflow (miliar Rp)</i>								
<b>Tahun</b>	<b>Bulan</b>	<b>1.000</b>	<b>2.000</b>	<b>5000</b>	<b>10.000</b>	<b>20.000</b>	<b>50.000</b>	<b>100.000</b>
2003	Januari	278,244	*	551,858	952,163	2096,296	12424,344	7666,245
2003	Februari	187,763	*	344,548	610,315	1399,736	8616,926	5308,464
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2015	November	18,625	337,163	533,887	657,349	663,971	14425,381	18856,685
2015	Desember	15,893	239,940	421,428	569,740	614,987	10632,061	13436,752
2016	Januari	17,933	224,858	492,776	713,442	797,266	27297,007	47141,781
2016	Februari	18,499	234,338	498,198	690,416	769,849	17300,484	27622,141
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2016	November	15,547	330,043	544,501	682,070	778,572	15030,069	22409,779
2016	Desember	478,174	568,097	657,851	13001,197	20162,623	13001,197	20162,623
<i>Outflow (miliar Rp)</i>								
2003	Januari	123,186	0,000	286,777	517,170	1192,291	8146,788	5275,028
2003	Februari	101,478	0,000	241,196	429,077	1092,891	8685,145	4274,460
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2015	November	3,199	120,876	209,522	386,563	498,633	14840,341	25280,419
2015	Desember	4,518	266,222	527,925	856,617	1049,066	29327,246	53484,049
2016	Januari	2,382	206,569	373,200	728,848	842,464	7867,459	8302,630
2016	Februari	2,283	134,584	231,286	400,095	505,229	12009,425	16450,722
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2016	November	2,844	134,953	229,844	427,907	474,291	16104,669	30681,523
2016	Desember	13,145	344,542	637,670	1054,799	1146,138	24550,124	52448,688

## Lampiran 2 PACF Data Simulasi





**Lampiran 2** PACF Data Simulasi (*Lanjutan*)

### Lampiran 3 Hasil Pengujian Terasvirta Data Simulasi

#### 1. Pengujian linieritas untuk data simulasi dengan *lag* nya.

Data	Input lag 1		Input lag 12		Input lag 1 dan 12		Input lag 1, 2, 11, 12, dan 13	
	$\chi^2$	<i>p-value</i>	$\chi^2$	<i>p-value</i>	$\chi^2$	<i>p-value</i>	$\chi^2$	<i>p-value</i>
Yt_11	9,690	0,008	0,019	0,991	43,268	0,000	268,805	0,000
Yt_12	9,502	0,009	0,256	0,880	49,549	0,000	327,720	0,000
Yt_13	12,339	0,002	0,035	0,983	52,299	0,000	268,342	0,000
Yt_14	10,532	0,005	0,034	0,983	45,152	0,000	312,264	0,000
Yt_15	10,314	0,006	0,006	0,997	50,493	0,000	296,575	0,000
Yt_21	10,199	0,006	0,370	0,831	32,137	0,000	141,736	0,000
Yt_22	8,733	0,013	0,636	0,728	33,726	0,000	148,193	0,000
Yt_23	12,281	0,002	0,218	0,897	36,761	0,000	151,685	0,000
Yt_24	10,745	0,005	0,160	0,923	31,806	0,000	142,745	0,000
Yt_25	11,246	0,004	0,336	0,845	37,438	0,000	151,358	0,000
Yt_31	11,967	0,003	0,036	0,982	39,899	0,000	180,554	0,000
Yt_32	11,205	0,004	0,587	0,746	45,995	0,000	192,601	0,000
Yt_33	13,206	0,001	0,046	0,977	44,591	0,000	160,934	0,000
Yt_34	11,539	0,003	0,006	0,997	41,236	0,000	144,557	0,000
Yt_35	11,095	0,004	0,010	0,995	42,745	0,000	180,160	0,000
Yt_41	12,916	0,002	0,427	0,808	34,002	0,000	109,892	0,000
Yt_42	11,239	0,004	1,245	0,537	36,141	0,000	115,310	0,000
Yt_43	14,080	0,001	0,263	0,877	37,870	0,000	110,498	0,000
Yt_44	12,822	0,002	0,322	0,851	34,007	0,000	101,783	0,000
Yt_45	12,626	0,002	0,537	0,765	37,556	0,000	116,024	0,000

#### 2. Pengujian linieritas untuk residual *time series regression* dengan *lag* nya.

Data	$\chi^2$	<i>p-value</i>	Data	$\chi^2$	<i>p-value</i>
Yt_11	0,601	0,741	Yt_31	13,760	0,001
Yt_12	0,909	0,635	Yt_32	1,497	0,473
Yt_13	1,210	0,546	Yt_33	3,863	0,145
Yt_14	1,387	0,500	Yt_34	2,450	0,294
Yt_15	3,268	0,195	Yt_35	5,660	0,059
Yt_21	1,747	0,418	Yt_41	0,580	0,748
Yt_22	4,611	0,100	Yt_42	1,352	0,509
Yt_23	0,873	0,646	Yt_43	0,158	0,924
Yt_24	3,939	0,140	Yt_44	0,786	0,675
Yt_25	1,816	0,403	Yt_45	0,103	0,950

**Lampiran 4** Perbandingan Kriteria dalam Pemilihan *Neuron* Model Dekomposisi *Quantile Regression Neural Network*

Data	Neuron	Crossing Training	Crossing Testing	RMSE	MAE	MdAE	MdAPE	MAPE
Yt_11	1	0	0	<b>2,20</b>	<b>1,51</b>	<b>0,91</b>	<b>2,80</b>	<b>3,79</b>
Yt_11	2	1	0	2,64	1,97	1,50	4,88	5,26
Yt_11	3	0	0	2,63	1,96	1,49	4,83	5,23
Yt_11	4	4	0	2,67	2,02	1,49	4,93	5,42
Yt_11	5	0	0	2,62	1,94	1,43	4,73	5,20
Yt_11	10	1	0	2,64	1,98	1,46	4,80	5,32
Yt_11	15	0	0	2,68	2,02	1,42	4,70	5,42
Yt_12	1	0	0	2,15	1,58	1,00	2,84	5,35
Yt_12	2	0	0	1,68	1,14	<b>0,48</b>	<b>1,35</b>	3,80
Yt_12	3	0	0	2,11	1,53	0,95	2,68	5,20
Yt_12	4	1	0	<b>1,54</b>	<b>1,13</b>	0,67	1,61	<b>3,69</b>
Yt_12	5	2	2	2,20	1,65	1,07	3,05	5,55
Yt_12	10	2	0	1,72	1,22	0,55	1,49	4,09
Yt_12	15	0	0	1,67	1,17	0,60	1,60	3,91
Yt_13	1	0	0	1,61	1,27	1,30	4,03	3,55
Yt_13	2	0	0	1,61	1,27	1,30	4,03	3,56
Yt_13	3	0	0	1,60	<b>1,25</b>	<b>1,22</b>	3,42	<b>3,55</b>
Yt_13	4	0	0	1,66	1,31	1,22	3,46	3,75
Yt_13	5	1	0	1,68	1,32	1,22	3,47	3,80
Yt_13	10	3	0	<b>1,60</b>	1,34	1,27	<b>2,85</b>	3,75
Yt_13	15	3	0	1,90	1,46	1,29	4,47	4,19
Yt_14	1	0	0	1,63	1,24	0,73	<b>1,90</b>	3,59
Yt_14	2	0	0	1,60	1,22	0,66	1,92	3,54
Yt_14	3	0	0	1,58	1,21	0,68	1,98	3,52
Yt_14	4	0	0	<b>1,57</b>	<b>1,21</b>	<b>0,65</b>	2,02	<b>3,51</b>
Yt_14	5	0	0	1,57	1,21	0,65	2,02	3,51
Yt_14	10	1	0	1,67	1,30	0,87	2,13	3,77
Yt_14	15	3	0	1,61	1,23	0,74	1,97	3,56
Yt_15	1	0	0	1,93	1,53	1,16	3,75	4,24
Yt_15	2	2	0	2,39	1,99	1,92	5,38	5,70
Yt_15	3	0	0	2,41	2,00	1,93	5,39	5,74
Yt_15	4	4	0	1,71	1,29	<b>1,00</b>	2,54	3,56
Yt_15	5	3	0	1,81	1,39	1,11	2,97	3,83
Yt_15	10	0	1	<b>1,70</b>	<b>1,28</b>	1,03	<b>2,40</b>	<b>3,50</b>
Yt_15	15	3	0	2,35	1,93	1,76	5,71	5,50
Yt_21	1	0	0	4,30	<b>3,31</b>	2,79	6,49	<b>7,92</b>
Yt_21	2	0	0	4,35	3,32	2,71	6,91	7,95
Yt_21	3	0	0	4,31	3,32	2,72	6,55	7,94
Yt_21	4	2	3	4,36	3,35	<b>2,71</b>	7,21	8,05
Yt_21	5	1	0	<b>4,29</b>	3,33	3,15	<b>6,27</b>	7,97
Yt_21	10	0	0	5,20	4,07	3,58	9,74	9,71
Yt_21	15	2	0	4,70	3,85	3,32	8,63	9,32

**Lampiran 4** Perbandingan Kriteria dalam Pemilihan *Neuron* Model Dekomposisi *Quantile Regression Neural Network* (Lanjutan)

Data	Neuron	Crossing Training	Crossing Testing	RMSE	MAE	MdAE	MdAPE	MAPE
Yt_22	1	0	0	4,39	3,38	2,78	6,22	8,30
Yt_22	2	0	0	4,54	3,51	2,93	7,33	8,48
Yt_22	3	0	0	4,55	3,52	2,88	7,24	8,48
Yt_22	4	0	0	4,61	3,75	2,88	8,27	9,10
Yt_22	5	2	0	4,62	3,44	2,88	<b>5,86</b>	8,22
Yt_22	10	1	0	<b>3,58</b>	<b>2,83</b>	<b>2,36</b>	6,71	<b>7,04</b>
Yt_22	15	3	0	4,92	3,96	3,54	8,52	9,55
Yt_23	1	0	0	4,30	3,46	3,06	6,34	8,87
Yt_23	2	0	0	4,34	3,52	3,19	6,41	8,99
Yt_23	3	0	0	4,22	3,33	2,74	6,69	8,59
Yt_23	4	3	0	4,12	3,08	2,15	<b>5,44</b>	8,17
Yt_23	5	0	0	4,12	3,13	2,42	6,73	8,15
Yt_23	10	2	0	4,15	3,12	2,23	5,64	8,29
Yt_23	15	0	0	<b>4,11</b>	<b>3,06</b>	<b>2,04</b>	6,17	<b>7,93</b>
Yt_24	1	0	0	3,98	2,97	<b>2,81</b>	<b>6,93</b>	7,22
Yt_24	2	0	0	3,95	2,97	2,93	7,04	7,23
Yt_24	3	0	0	3,88	2,87	3,07	7,01	7,02
Yt_24	4	4	0	<b>3,80</b>	<b>2,81</b>	3,07	7,14	<b>6,97</b>
Yt_24	5	2	0	3,92	2,92	2,97	6,96	7,12
Yt_24	10	3	0	3,87	2,88	3,07	7,04	7,06
Yt_24	15	2	0	3,86	2,88	3,06	7,03	7,06
Yt_25	1	0	0	4,30	3,32	2,13	6,43	8,54
Yt_25	2	0	0	4,30	3,32	2,12	6,43	8,54
Yt_25	3	1	0	<b>4,19</b>	<b>3,04</b>	<b>1,82</b>	<b>5,51</b>	<b>8,04</b>
Yt_25	4	1	0	4,27	3,25	2,10	6,46	8,39
Yt_25	5	0	0	4,34	3,44	2,24	6,41	8,84
Yt_25	10	1	0	4,23	3,19	2,10	6,49	8,28
Yt_25	15	9	0	4,41	3,50	2,42	6,64	8,94
Yt_31	1	0	0	<b>3,67</b>	3,12	2,54	6,72	8,71
Yt_31	2	1	6	4,54	3,26	2,62	6,36	9,22
Yt_31	3	2	6	4,43	3,22	2,56	6,24	9,07
Yt_31	4	1	0	4,20	<b>3,08</b>	<b>1,96</b>	<b>6,20</b>	<b>8,63</b>
Yt_31	5	0	2	4,12	3,27	2,17	7,64	9,06
Yt_31	10	5	4	4,12	3,36	2,46	8,16	9,50
Yt_31	15	2	4	4,42	3,48	3,15	8,81	10,00
Yt_32	1	0	0	3,19	2,67	2,59	<b>7,07</b>	8,60
Yt_32	2	0	0	3,18	2,66	2,56	7,23	8,55
Yt_32	3	1	0	3,18	2,66	2,55	7,27	8,54
Yt_32	4	1	0	3,33	2,78	2,61	7,11	8,97
Yt_32	5	1	0	3,15	2,64	2,34	7,90	8,39
Yt_32	10	2	0	<b>3,15</b>	<b>2,64</b>	2,34	7,86	<b>8,40</b>
Yt_32	15	0	0	3,83	3,05	<b>2,25</b>	7,09	9,64

**Lampiran 4** Perbandingan Kriteria dalam Pemilihan *Neuron* Model Dekomposisi *Quantile Regression Neural Network* (Lanjutan)


Data	Neuron	Crossing Training	Crossing Testing	RMSE	MAE	MdAE	MdAPE	MAPE
Yt_33	1	0	0	<b>3,18</b>	<b>2,75</b>	<b>2,40</b>	<b>7,05</b>	<b>8,16</b>
Yt_33	2	0	0	3,32	2,84	2,52	7,23	8,48
Yt_33	3	0	0	3,32	2,84	2,52	7,23	8,49
Yt_33	4	0	0	3,38	2,87	2,49	7,39	8,60
Yt_33	5	0	0	3,31	2,83	2,56	7,15	8,45
Yt_33	10	2	2	3,33	2,84	2,56	7,21	8,50
Yt_33	15	4	1	3,31	2,83	2,57	7,08	8,46
Yt_34	1	0	0	<b>3,83</b>	<b>3,43</b>	3,47	<b>9,46</b>	<b>9,95</b>
Yt_34	2	0	0	4,05	3,66	3,45	9,71	10,60
Yt_34	3	0	0	3,96	3,63	3,57	10,17	10,51
Yt_34	4	0	0	4,08	3,71	3,54	10,01	10,72
Yt_34	5	1	4	4,05	3,67	3,50	9,83	10,63
Yt_34	10	0	3	4,04	3,66	3,46	9,72	10,59
Yt_34	15	0	2	4,03	3,67	<b>3,20</b>	9,80	10,65
Yt_35	1	0	0	<b>3,16</b>	<b>2,49</b>	2,37	6,38	<b>6,85</b>
Yt_35	2	0	0	3,61	2,99	2,55	6,17	8,34
Yt_35	3	1	0	3,61	2,99	2,55	6,17	8,34
Yt_35	4	0	6	3,38	2,73	2,55	6,36	7,58
Yt_35	5	0	6	3,40	2,74	2,55	6,36	7,60
Yt_35	10	6	0	3,49	3,01	2,44	7,35	8,56
Yt_35	15	0	4	3,75	2,87	<b>2,02</b>	<b>5,47</b>	8,03
Yt_41	1	0	0	4,05	3,56	3,85	10,01	9,45
Yt_41	2	0	0	4,05	3,56	3,85	10,01	9,45
Yt_41	3	1	0	4,06	3,59	3,85	10,27	9,50
Yt_41	4	4	0	4,43	3,70	<b>3,16</b>	10,37	9,75
Yt_41	5	1	0	4,12	3,59	3,55	10,26	9,49
Yt_41	10	1	1	<b>4,02</b>	<b>3,47</b>	3,55	<b>9,47</b>	<b>9,19</b>
Yt_41	15	1	0	4,06	3,58	3,77	10,00	9,48
Yt_42	1	0	0	4,18	3,50	3,41	7,94	10,00
Yt_42	2	0	0	4,18	3,51	3,41	7,94	10,00
Yt_42	3	0	0	4,24	3,51	3,41	8,01	10,39
Yt_42	4	0	0	4,81	3,93	4,26	9,97	11,25
Yt_42	5	0	0	4,34	3,49	4,15	9,72	10,05
Yt_42	10	1	3	4,18	3,42	3,36	8,11	10,19
Yt_42	15	0	3	<b>4,12</b>	<b>3,30</b>	<b>2,72</b>	<b>6,41</b>	<b>9,69</b>
Yt_43	1	0	0	4,37	3,76	3,22	8,40	9,91
Yt_43	2	1	0	4,04	3,45	<b>2,66</b>	7,70	9,42
Yt_43	3	0	0	4,25	3,65	2,97	8,50	9,70
Yt_43	4	0	0	4,45	3,82	3,47	8,16	10,57
Yt_43	5	2	0	<b>4,03</b>	<b>3,39</b>	2,87	<b>6,74</b>	<b>9,35</b>
Yt_43	10	3	1	5,06	3,84	3,13	9,13	10,10
Yt_43	15	0	0	5,82	4,60	4,11	9,06	11,74

**Lampiran 4** Perbandingan Kriteria dalam Pemilihan *Neuron* Model Dekomposisi *Quantile Regression Neural Network* (Lanjutan)

Data	Neuron	Crossing Training	Crossing Testing	RMSE	MAE	MdAE	MdAPE	MAPE
Yt_44	1	0	0	5,22	4,51	4,11	10,43	11,54
Yt_44	2	1	0	5,43	4,62	4,30	11,50	11,71
Yt_44	3	0	0	5,55	4,71	4,52	11,16	11,89
Yt_44	4	1	3	5,53	4,69	4,67	11,55	11,85
Yt_44	5	2	0	<b>4,23</b>	<b>3,50</b>	<b>3,62</b>	10,16	<b>9,87</b>
Yt_44	10	0	0	5,49	4,72	4,28	<b>10,12</b>	12,02
Yt_44	15	0	1	4,98	4,35	4,76	12,52	11,47
Yt_45	1	0	0	4,10	3,45	2,73	8,28	9,15
Yt_45	2	0	0	4,20	3,58	2,95	8,72	9,35
Yt_45	3	1	0	4,00	<b>3,32</b>	<b>2,58</b>	8,63	8,83
Yt_45	4	0	0	4,14	3,50	2,73	8,82	9,24
Yt_45	5	1	0	4,33	3,70	3,30	8,99	9,56
Yt_45	10	1	1	<b>3,77</b>	3,45	3,33	<b>7,97</b>	9,41
Yt_45	15	2	0	4,10	3,55	3,11	8,75	<b>8,63</b>


## Lampiran 5 Identifikasi Heterogen dalam Musiman untuk Setiap Pecahan *Inflow*.

### a. *Boxplot* data asli



## Lampiran 5 Identifikasi Heterogen dalam Musiman untuk Setiap Pecahan *Inflow* (Lanjutan)


### b. *Boxplot* data *inflow* tanpa variasi kalender





## Lampiran 5 Identifikasi Heterogen dalam Musiman untuk Setiap Pecahan *Inflow* (Lanjutan)

### c. *Boxplot* data *inflow* tanpa tren dan variasi kalender



## Lampiran 6 Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX

### A. Inflow Pecahan Rp 1.000,00

#### Pemodelan TSR

- Estimasi parameter


Variabel	Estimasi	SE	<i>t</i> -value	<i>p</i> -value
xt	-1,23	0,05	-24,41	0,00
xM1	233,61	8,70	26,85	0,00
xM2	219,05	8,54	25,64	0,00
xM3	216,39	8,57	25,26	0,00
xM4	197,11	8,59	22,95	0,00
xM5	188,58	8,61	21,90	0,00
xM6	176,25	8,63	20,41	0,00
xM7	175,05	8,80	19,88	0,00
xM8	168,09	9,12	18,43	0,00
xM9	163,35	9,14	17,87	0,00
xM10	177,72	9,32	19,07	0,00
xM11	201,64	9,56	21,10	0,00
xM12	217,64	9,11	23,88	0,00
xC1t	20,85	20,65	1,01	0,31
xC2t	-0,59	16,86	-0,04	0,97
xC3t	-20,66	14,60	-1,42	0,16
xC4t	-40,92	14,59	-2,80	0,01
xC1tp1	74,28	16,90	4,39	0,00
xC2tp1	49,22	16,87	2,92	0,00
xC3tp1	46,80	14,60	3,21	0,00
xC4tp1	30,83	14,60	2,11	0,04

- Pengujian residual TSR

<i>Ljung-Box test</i>			<i>LM test</i>						<i>KS test</i>	
<i>Lag</i>	$\chi^2$	<i>p</i> -value	<i>Lag</i>	$\chi^2$	<i>p</i> -value	<i>Lag</i>	$\chi^2$	<i>p</i> -value	<i>D</i>	<i>p</i> -value
12	104,21	0,00	1	0,05	0,82	7	11,39	0,12	0,06	0,69
24	136,74	0,00	2	7,81	0,02	8	11,18	0,19		
36	161,08	0,00	3	8,12	0,04	9	11,32	0,25		
48	174,42	0,00	4	9,52	0,05	10	11,44	0,32		
60	177,67	0,00	5	10,46	0,06	11	16,15	0,14		
			6	10,47	0,11	12	21,20	0,05		

#### Pemodelan ARIMA

- identifikasi



## Lampiran 6 Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)

- Estimasi parameter

Parameter	Estimasi	p-value
ar1	0,36	0,00
ar11	0,32	0,00
ar12	0,37	0,00
ar13	-0,27	0,00

- Pengujian residual ARIMA

<i>Ljung-Box test</i>			<i>LM test</i>						<i>KS test</i>	
Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	D	p-value
12	15,57	0,21	1	0,04	0,83	7	7,63	0,37	0,08	0,23
24	26,29	0,34	2	5,57	0,06	8	7,79	0,45		
36	38,49	0,36	3	5,90	0,12	9	7,73	0,56		
48	48,78	0,44	4	7,12	0,13	10	7,94	0,63		
60	52,79	0,73	5	7,16	0,21	11	9,86	0,54		
			6	7,26	0,30	12	10,01	0,61		

## B. Inflow Pecahan Rp 2.000,00

### Pemodelan TSR

- Estimasi parameter

Variabel	Estimasi	SE	t-value	p-value
xt	3,32	0,31	10,67	0,00
xM1	-179,45	43,48	-4,13	0,00
xM2	-195,80	43,74	-4,48	0,00
xM3	-204,54	43,99	-4,65	0,00
xM4	-233,50	44,25	-5,28	0,00
xM5	-254,33	44,51	-5,71	0,00
xM6	-266,15	44,77	-5,95	0,00
xM7	-254,81	46,49	-5,48	0,00
xM8	-166,92	47,18	-3,54	0,00
xM9	-65,30	47,74	-1,37	0,18
xM10	-81,65	44,67	-1,83	0,07
xM11	-160,86	43,53	-3,70	0,00
xM12	-194,47	43,79	-4,44	0,00
xC2t	-155,17	49,49	-3,14	0,00
xC3t	-144,02	40,45	-3,56	0,00
xC4t	-95,47	48,14	-1,98	0,05
xC2tp1	-9,51	47,71	-0,20	0,84
xC3tp1	-78,64	40,14	-1,96	0,05
xC4tp1	-66,83	49,46	-1,35	0,18


- Pengujian residual TSR

<i>Ljung-Box test</i>			<i>LM test</i>						<i>KS test</i>	
Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	D	p-value
12	105,93	0,00	1	8,62	0,00	7	8,77	0,27	0,047659,	0,99
24	124,41	0,00	2	12,88	0,00	8	9,01	0,34		
36	171,33	0,00	3	12,15	0,01	9	9,92	0,36		
48	191,27	0,00	4	10,00	0,04	10	12,31	0,27		
60	194,30	0,00	5	8,72	0,12	11	12,86	0,30		
			6	7,97	0,24	12	12,47	0,41		

**Lampiran 6** *Output* Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (*Lanjutan*)

**Pemodelan ARIMA**

- identifikasi



- Estimasi parameter

Parameter	Estimasi	p-value
ar1	0,72	0,00

- Pengujian residual ARIMA

<i>Ljung-Box test</i>			<i>LM test</i>						<i>KS test</i>	
Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	D	p-value
12	10,38	0,58	1	0,33	0,56	7	2,71	0,91	0,076951,	0,72
24	20,47	0,67	2	0,57	0,75	8	2,91	0,94		
36	28,92	0,79	3	0,88	0,83	9	3,42	0,95		
48	37,41	0,86	4	1,36	0,85	10	4,32	0,93		
60	41,60	0,97	5	1,30	0,93	11	4,71	0,94		
			6	2,91	0,82	12	5,46	0,94		

**C. Inflow Pecahan Rp 5.000,00**

**Pemodelan TSR**

- Estimasi parameter

Variabel	Estimasi	SE	t-value	p-value
xt	1,32	0,25	5,31	0,00
xM1	372,40	43,07	8,65	0,00
xM2	308,32	42,30	7,29	0,00
xM3	291,22	42,41	6,87	0,00
xM4	242,28	42,52	5,70	0,00
xM5	207,76	42,63	4,87	0,00
xM6	188,53	42,75	4,41	0,00
xM7	202,18	43,58	4,64	0,00
xM8	307,17	45,16	6,80	0,00
xM9	391,22	45,27	8,64	0,00
xM10	361,26	46,13	7,83	0,00
xM11	324,21	47,31	6,85	0,00
xM12	256,95	45,12	5,69	0,00
xC1t	100,22	102,24	0,98	0,33
xC2t	-137,60	83,47	-1,65	0,10
xC3t	-158,79	72,26	-2,20	0,03

## Lampiran 6 Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)


Variabel	Estimasi	SE	t-value	p-value
xC4t	-192,59	72,24	-2,67	0,01
xC1tp1	210,68	83,69	2,52	0,01
xC2tp1	184,06	83,53	2,20	0,03
xC3tp1	329,54	72,29	4,56	0,00
xC4tp1	224,31	72,30	3,10	0,00

- Pengujian residual TSR

Ljung-Box test			LM test						KS test	
Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	D	p-value
12	173,36	0,00	1	4,01	0,05	7	7,31	0,40	0,13771,	0,01
24	228,40	0,00	2	4,75	0,09	8	7,83	0,45		
36	245,23	0,00	3	5,16	0,16	9	8,70	0,47		
48	263,98	0,00	4	5,54	0,24	10	8,94	0,54		
60	301,96	0,00	5	6,16	0,29	11	25,06	0,01		
			6	6,57	0,36	12	46,72	0,00		

### Pemodelan ARIMA

- identifikasi



- Estimasi parameter

Parameter	Estimasi	p-value
ar1	0,30	0,00
ar2	0,23	0,00
ar12	0,53	0,00
ar14	-0,35	0,00
ma23	0,73	0,00


- Pengujian residual ARIMA

Ljung-Box test			LM test						KS test	
Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	D	p-value
12	15,39	0,22	1	0,04	0,84	7	6,77	0,45	0,091698,	0,15
24	28,51	0,24	2	2,00	0,37	8	7,28	0,51		
36	45,43	0,13	3	2,23	0,53	9	8,02	0,53		
48	51,57	0,34	4	3,68	0,45	10	8,76	0,56		
60	62,34	0,39	5	5,02	0,41	11	35,49	0,00		
			6	5,74	0,45	12	39,06	0,00		

## Lampiran 6 Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)

### Pemodelan GARCH

- identifikasi orde GARCH



- Estimasi parameter

Parameter	Estimasi	SE	t-value	p-value
ARCH0	4686,00	591,76	7,92	0,00
ARCH11	0,18	0,08	2,16	0,03

## D. Inflow Pecahan Rp 10.000,00

### Pemodelan TSR

- Estimasi parameter

Variabel	Estimasi	SE	t-value	p-value
xt	1,05	0,32	3,26	0,00
xM1	582,24	55,83	10,43	0,00
xM2	475,59	54,83	8,67	0,00
xM3	456,61	54,97	8,31	0,00
xM4	401,79	55,12	7,29	0,00
xM5	363,29	55,26	6,57	0,00
xM6	335,08	55,41	6,05	0,00
xM7	367,15	56,49	6,50	0,00
xM8	492,19	58,53	8,41	0,00
xM9	537,63	58,67	9,16	0,00
xM10	512,23	59,80	8,57	0,00
xM11	469,39	61,33	7,65	0,00
xM12	380,54	58,49	6,51	0,00
xC1t	66,63	132,53	0,50	0,62
xC2t	-71,14	108,19	-0,66	0,51
xC3t	-101,50	93,67	-1,08	0,28
xC4t	-195,41	93,64	-2,09	0,04
xC1tp1	182,00	108,48	1,68	0,10
xC2tp1	233,11	108,27	2,15	0,03
xC3tp1	524,91	93,71	5,60	0,00
xC4tp1	494,00	93,71	5,27	0,00


## Lampiran 6 Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)

- Pengujian residual TSR

<i>Ljung-Box test</i>			<i>LM test</i>			<i>KS test</i>	
<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>D</i>	<i>p-value</i>
12	273,45	0,00	1	4,83	0,03	0,12307,	0,02
24	329,28	0,00	2	4,99	0,08		
36	338,13	0,00	3	4,99	0,17		
48	348,33	0,00	4	5,12	0,27		
60	436,80	0,00	5	5,25	0,39		
			6	5,26	0,51		
			7	5,42	0,61		
			8	5,74	0,68		
			9	5,87	0,75		
			10	5,82	0,83		
			11	29,83	0,00		
			12	32,99	0,00		

### Pemodelan ARIMA

- identifikasi



- Estimasi parameter

Parameter	Estimasi	<i>p-value</i>
ma1	-0,77	0,00
sma1	0,71	0,00
sma2	0,33	0,00


- Pengujian residual ARIMA

<i>Ljung-Box test</i>			<i>LM test</i>			<i>KS test</i>	
<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>D</i>	<i>p-value</i>
12	8,52	0,74	1	1,46	0,23	0,12176,	0,02
24	29,15	0,21	2	1,50	0,47		
36	45,15	0,14	3	1,75	0,63		
48	53,37	0,28	4	2,91	0,57		
60	68,36	0,21	5	3,17	0,67		
			6	3,41	0,76		
			7	4,65	0,70		
			8	4,67	0,79		
			9	5,68	0,77		
			10	6,22	0,80		
			11	26,59	0,01		
			12	36,74	0,00		

## Lampiran 6 Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)

### Pemodelan GARCH

- identifikasi orde GARCH



- Estimasi parameter

Parameter	Estimasi	SE	t-value	p-value
ARCH0	13429,00	1824,00	7,36	0,00
ARCH11	0,28	0,13	2,15	0,03

### E. Inflow Pecahan Rp 20.000,00

#### Pemodelan TSR

- Estimasi parameter

Variabel	Estimasi	SE	t-value	p-value
xt	-7,05	0,57	-12,39	0,00
xM1	1680,32	98,45	17,07	0,00
xM2	1467,96	96,68	15,18	0,00
xM3	1447,34	96,93	14,93	0,00
xM4	1377,35	97,18	14,17	0,00
xM5	1336,02	97,44	13,71	0,00
xM6	1325,71	97,70	13,57	0,00
xM7	1381,59	99,61	13,87	0,00
xM8	1481,29	103,20	14,35	0,00
xM9	1494,99	103,45	14,45	0,00
xM10	1516,72	105,43	14,39	0,00
xM11	1500,61	108,13	13,88	0,00
xM12	1402,62	103,13	13,60	0,00
xC1t	534,14	233,67	2,29	0,02
xC2t	-75,77	190,76	-0,40	0,69
xC3t	124,01	165,15	0,75	0,45
xC4t	-225,66	165,11	-1,37	0,17
xC1tp1	284,91	191,27	1,49	0,14
xC2tp1	93,67	190,91	0,49	0,62
xC3tp1	728,51	165,23	4,41	0,00
xC4tp1	935,59	165,23	5,66	0,00




## Lampiran 6 Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)

- Pengujian residual TSR

<i>Ljung-Box test</i>			<i>LM test</i>				<i>KS test</i>	
<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>
12	787,55	0,00	1	18,73	0,00	7	19,28	0,01
24	997,73	0,00	2	18,82	0,00	8	18,97	0,02
36	1014,88	0,00	3	20,87	0,00	9	18,97	0,03
48	1149,82	0,00	4	20,44	0,00	10	20,88	0,02
60	1374,73	0,00	5	20,06	0,00	11	23,13	0,02
			6	19,69	0,00	12	32,94	0,00
							D	<i>p-value</i>
							0,069192,	0,44

### Pemodelan ARIMA

- identifikasi



- Estimasi parameter

Parameter	Estimasi	<i>p-value</i>
ar1	-0,57	0,00
ar2	-0,39	0,00


- Pengujian residual ARIMA

<i>Ljung-Box test</i>			<i>LM test</i>				<i>KS test</i>	
<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>
12	9,84	0,63	1	6,06	0,01	7	11,51	0,12
24	28,67	0,23	2	6,03	0,05	8	12,44	0,13
36	39,19	0,33	3	6,31	0,10	9	13,37	0,15
48	54,00	0,26	4	7,93	0,09	10	13,11	0,22
60	60,50	0,46	5	8,50	0,13	11	17,82	0,09
			6	10,33	0,11	12	22,00	0,04
							D	<i>p-value</i>
							0,094169,	0,13

## Lampiran 6 Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)

### Pemodelan GARCH

- identifikasi orde GARCH



- Estimasi parameter

Parameter	Estimasi	SE	t-value	p-value
omega	19800,00	2981,00	6,64	0,00
alpha1	0,30	0,13	2,34	0,02

## F. Inflow Pecahan Rp 50.000,00

### Pemodelan TSR

- Estimasi parameter

Variabel	Estimasi	SE	t-value	p-value
xt	16,00	7,20	2,22	0,03
xM1	15243,00	1245,20	12,24	0,00
xM2	9727,50	1222,90	7,96	0,00
xM3	9173,90	1226,00	7,48	0,00
xM4	9129,50	1229,20	7,43	0,00
xM5	8666,00	1232,40	7,03	0,00
xM6	8659,00	1235,70	7,01	0,00
xM7	10278,90	1259,90	8,16	0,00
xM8	10700,00	1305,30	8,20	0,00
xM9	9034,50	1308,50	6,90	0,00
xM10	10666,00	1333,60	8,00	0,00
xM11	8378,80	1367,70	6,13	0,00
xM12	6281,30	1304,40	4,82	0,00
xC1t	12699,80	2955,60	4,30	0,00
xC2t	9188,50	2412,80	3,81	0,00
xC3t	7252,90	2088,90	3,47	0,00
xC4t	-2568,00	2088,30	-1,23	0,22
xC1tp1	563,60	2419,20	0,23	0,82
xC2tp1	-757,80	2414,70	-0,31	0,75
xC3tp1	6425,00	2089,90	3,07	0,00
xC4tp1	15642,40	2089,90	7,49	0,00


## Lampiran 6 Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)

- Pengujian residual TSR

Ljung-Box test			LM test				KS test			
Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	D	p-value
12	641,24	0,00	1	6,10	0,01	7	15,22	0,03	0,063369,	0,56
24	757,92	0,00	2	9,24	0,01	8	14,67	0,07		
36	773,15	0,00	3	12,25	0,01	9	14,90	0,09		
48	879,58	0,00	4	11,90	0,02	10	14,45	0,15		
60	1093,36	0,00	5	14,76	0,01	11	19,02	0,06		
			6	15,63	0,02	12	19,22	0,08		

### Pemodelan ARIMA

- identifikasi



- Estimasi parameter

Parameter	Estimasi	<i>p-value</i>
ar1	-0,73	0,00
ar2	-0,32	0,00

- Pengujian residual ARIMA

Ljung-Box test			LM test						KS test	
Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	D	p-value
12	4,95	0,96	1	0,29	0,59	7	2,48	0,93	0,11382,	0,04
24	22,84	0,53	2	0,54	0,76	8	3,25	0,92		
36	26,65	0,87	3	1,34	0,72	9	3,41	0,95		
48	36,19	0,89	4	1,80	0,77	10	4,30	0,93		
60	43,05	0,95	5	1,91	0,86	11	4,67	0,95		
			6	2,22	0,90	12	15,41	0,22		

**Lampiran 6** *Output* Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (*Lanjutan*)

**G. Inflow Pecahan Rp 100.000,00**

**Pemodelan TSR**

- Estimasi parameter


Variabel	Estimasi	SE	t-value	p-value
xt	129,02	10,38	12,43	0,00
xM1	7822,14	1795,56	4,36	0,00
xM2	477,28	1763,40	0,27	0,79
xM3	-578,25	1767,94	-0,33	0,74
xM4	-918,87	1772,54	-0,52	0,61
xM5	-1130,84	1777,19	-0,64	0,53
xM6	-1329,57	1781,88	-0,75	0,46
xM7	825,95	1816,84	0,46	0,65
xM8	2960,37	1882,32	1,57	0,12
xM9	-1728,94	1886,93	-0,92	0,36
xM10	-134,85	1923,01	-0,07	0,94
xM11	-3062,16	1972,25	-1,55	0,12
xM12	-5694,64	1881,00	-3,03	0,00
xC1t	12122,48	4262,02	2,84	0,01
xC2t	15549,24	3479,33	4,47	0,00
xC3t	11413,76	3012,28	3,79	0,00
xC4t	-2055,48	3011,39	-0,68	0,50
xC1tp1	2697,41	3488,53	0,77	0,44
xC2tp1	-845,33	3481,98	-0,24	0,81
xC3tp1	5408,14	3013,61	1,80	0,07
xC4tp1	22368,04	3013,69	7,42	0,00

- Pengujian residual TSR

Ljung-Box test			LM test						KS test	
Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	D	p-value
12	231,15	0,00	1	0,19	0,66	7	25,51	0,00	0,075534,	0,34
24	300,69	0,00	2	1,40	0,50	8	25,38	0,00		
36	308,66	0,00	3	3,01	0,39	9	25,25	0,00		
48	364,07	0,00	4	5,84	0,21	10	27,39	0,00		
60	480,21	0,00	5	13,33	0,02	11	28,70	0,00		
			6	21,80	0,00	12	48,34	0,00		

**Pemodelan ARIMA**

- identifikasi



## Lampiran 6 Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)

- Estimasi parameter


Parameter	Estimasi	p-value
ar1	-0,89	0,00
ar2	-0,65	0,00
ar3	-0,47	0,00
ar4	-0,33	0,00

- Pengujian residual ARIMA

<i>Ljung-Box test</i>			<i>LM test</i>			<i>KS test</i>		
Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value
12	16,05	0,19	1	0,40	0,53	7	4,38	0,73
24	25,87	0,36	2	0,56	0,76	8	4,53	0,81
36	28,59	0,81	3	0,95	0,81	9	4,59	0,87
48	37,92	0,85	4	1,28	0,86	10	4,70	0,91
60	45,00	0,93	5	3,34	0,65	11	24,01	0,01
			6	3,51	0,74	12	38,44	0,00

### Pemodelan GARCH

- identifikasi orde GARCH



- Estimasi parameter

Parameter	Estimasi	SE	t-value	p-value
ARCH0	20420256,00	1992568,00	10,25	0,00
ARCH12	0,22	0,09	2,34	0,02

## H. Outflow Pecahan Rp 1.000,00

### Pemodelan TSR

- Estimasi parameter

Variabel	Estimasi	SE	t-value	p-value
xt	-1,43	0,08	-17,72	0,00
xM1	188,31	13,72	13,73	0,00
xM2	174,74	13,75	12,71	0,00
xM3	177,00	13,79	12,84	0,00
xM4	177,46	13,82	12,84	0,00
xM5	179,35	13,86	12,94	0,00
xM6	180,65	14,13	12,78	0,00

**Lampiran 6** *Output* Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (*Lanjutan*)


Variabel	Estimasi	SE	t-value	p-value
xM7	165,61	14,64	11,31	0,00
xM8	209,69	14,68	14,29	0,00
xM9	219,62	14,96	14,68	0,00
xM10	228,33	15,39	14,83	0,00
xM11	186,02	14,67	12,68	0,00
xM12	196,82	14,12	13,94	0,00
xC1t	-36,20	33,20	-1,09	0,28
xC2t	78,33	27,21	2,88	0,00
xC3t	126,91	23,54	5,39	0,00
xC4t	242,08	23,55	10,28	0,00
xC1tp1	340,34	33,29	10,22	0,00
xC2tp1	109,58	27,17	4,03	0,00
xC3tp1	45,65	23,53	1,94	0,05
xC4tp1	50,76	23,52	2,16	0,03

• Pengujian residual TSR

<i>Ljung-Box test</i>			<i>LM test</i>						<i>KS test</i>	
Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	D	p-value
12	145,54	0,00	1	13,11	0,00	7	15,02	0,04	0,06	0,64
24	152,76	0,00	2	13,01	0,00	8	14,86	0,06		
36	165,92	0,00	3	12,83	0,01	9	15,92	0,07		
48	216,27	0,00	4	14,01	0,01	10	17,29	0,07		
60	286,47	0,00	5	14,47	0,01	11	17,85	0,09		
			6	14,80	0,02	12	19,12	0,09		

**Pemodelan ARIMA**

• identifikasi



• Estimasi parameter

Parameter	Estimasi	p-value
ar1	0,56	0,00


## Lampiran 6 Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)

- Pengujian residual ARIMA

<i>Ljung-Box test</i>			<i>LM test</i>						<i>KS test</i>	
<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>D</i>	<i>p-value</i>
12	7,36	0,83	1	18,67	0,00	7	23,45	0,00	0,12	0,02
24	24,08	0,46	2	19,88	0,00	8	24,34	0,00		
36	28,68	0,80	3	20,87	0,00	9	25,21	0,00		
48	44,78	0,61	4	20,70	0,00	10	25,51	0,00		
60	55,54	0,64	5	22,54	0,00	11	26,33	0,01		
			6	23,06	0,00	12	29,92	0,00		

### Pemodelan GARCH

- identifikasi orde GARCH



- Estimasi parameter

Parameter	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
omega	797,53	113,16	7,05	0,00
alpha1	0,30	0,12	2,42	0,02

## I. Outflow Pecahan Rp 2.000,00

### Pemodelan TSR

- Estimasi parameter

Variabel	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
xt	1,62	0,43	3,77	0,00
xM1	-52,93	59,84	-0,88	0,38
xM2	-58,79	60,20	-0,98	0,33
xM3	-53,58	60,55	-0,89	0,38
xM4	-28,93	60,91	-0,48	0,64
xM5	29,87	61,27	0,49	0,63
xM6	80,03	64,57	1,24	0,22
xM7	-22,96	72,68	-0,32	0,75
xM8	-297,26	67,48	-4,41	0,00
xM9	-119,48	61,64	-1,94	0,06
xM10	-111,97	59,55	-1,88	0,07
xM11	-95,41	59,92	-1,59	0,12
xM12	-13,82	60,28	-0,23	0,82

## Lampiran 6 Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)


Variabel	Estimasi	SE	t-value	p-value
xC2t	220,22	65,83	3,35	0,00
xC3t	769,01	56,44	13,63	0,00
xC4t	1523,51	69,83	21,82	0,00
xC2tp1	1458,71	70,14	20,80	0,00
xC3tp1	760,29	57,03	13,33	0,00
xC4tp1	168,77	67,60	2,50	0,02

- Pengujian residual TSR

Ljung-Box test			LM test				KS test	
Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value
12	18,14	0,11	1	23,16	0,00	7	25,36	0,00
24	21,54	0,61	2	26,32	0,00	8	25,04	0,00
36	25,63	0,90	3	26,23	0,00	9	24,82	0,00
48	29,13	0,99	4	26,28	0,00	10	26,53	0,00
60	41,61	0,97	5	25,88	0,00	11	27,36	0,00
			6	25,65	0,00	12	28,97	0,00

### Pemodelan ARIMA

- identifikasi



- Estimasi parameter

Parameter	Estimasi	p-value
ar1	-0,36	0,00

- Pengujian residual ARIMA


Ljung-Box test			LM test						KS test	
Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	D	p-value
12	9,05	0,70	1	10,26	0,00	7	13,26	0,07	0,16	0,03
24	15,41	0,91	2	12,05	0,00	8	13,01	0,11		
36	18,88	0,99	3	13,72	0,00	9	12,82	0,17		
48	24,45	1,00	4	13,64	0,01	10	16,82	0,08		
60	32,73	1,00	5	13,54	0,02	11	17,46	0,09		
			6	13,48	0,04	12	18,81	0,09		



## Lampiran 6 Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)

### Pemodelan GARCH

- identifikasi orde GARCH



- Estimasi parameter

Parameter	Estimasi	SE	t-value	p-value
omega	1270,79	401,02	3,17	0,00
alpha l	1,00	0,36	2,80	0,01

## J. Outflow Pecahan Rp 5.000,00

### Pemodelan TSR

- Estimasi parameter

Variabel	Estimasi	SE	t-value	p-value
xt	1,47	0,50	2,95	0,00
xM1	175,35	85,15	2,06	0,04
xM2	148,51	85,36	1,74	0,08
xM3	159,60	85,58	1,87	0,06
xM4	205,35	85,80	2,39	0,02
xM5	253,25	86,02	2,94	0,00
xM6	381,42	87,71	4,35	0,00
xM7	546,70	90,88	6,02	0,00
xM8	176,93	91,11	1,94	0,05
xM9	3,22	92,84	0,04	0,97
xM10	-117,11	95,54	-1,23	0,22
xM11	-85,85	91,03	-0,94	0,35
xM12	211,28	87,65	2,41	0,02
xC1t	238,86	206,04	1,16	0,25
xC2t	298,49	168,86	1,77	0,08
xC3t	987,56	146,14	6,76	0,00
xC4t	1610,17	146,20	11,01	0,00
xC1tp1	1383,84	206,65	6,70	0,00
xC2tp1	1655,93	168,67	9,82	0,00
xC3tp1	1048,22	146,07	7,18	0,00
xC4tp1	318,11	146,02	2,18	0,03


**Lampiran 6** *Output* Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (*Lanjutan*)

- Pengujian residual TSR

<i>Ljung-Box test</i>			<i>LM test</i>						<i>KS test</i>	
<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>D</i>	<i>p-value</i>
12	23,33	0,03	1	0,10	0,75	7	5,77	0,57	0,16	0,00
24	55,00	0,00	2	0,24	0,89	8	7,45	0,49		
36	65,01	0,00	3	0,92	0,82	9	8,89	0,45		
48	82,09	0,00	4	1,86	0,76	10	9,27	0,51		
60	89,64	0,01	5	2,89	0,72	11	27,41	0,00		
			6	4,21	0,65	12	34,66	0,00		

**Pemodelan ARIMA**

- identifikasi



- Estimasi parameter

Parameter	Estimasi	<i>p-value</i>
ar11	0,17	0,02
ar12	0,21	0,00
ar23	0,46	0,00


- Pengujian residual ARIMA

<i>Ljung-Box test</i>			<i>LM test</i>						<i>KS test</i>	
<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>D</i>	<i>p-value</i>
12	7,57	0,82	1	4,23	0,04	7	9,44	0,22	0,15	0,00
24	18,33	0,79	2	4,34	0,11	8	10,92	0,21		
36	31,51	0,68	3	4,46	0,22	9	11,09	0,27		
48	40,69	0,76	4	6,02	0,20	10	11,20	0,34		
60	47,40	0,88	5	6,95	0,22	11	24,32	0,01		
			6	8,15	0,23	12	36,96	0,00		

## Lampiran 6 Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)

### Pemodelan GARCH

- identifikasi orde GARCH



- Estimasi parameter

Parameter	Estimasi	SE	t-value	p-value
ARCH0	44033,00	5505,00	8,00	0,00
ARCH11	0,29	0,13	2,29	0,02

## K. Outflow Pecahan Rp 10.000,00

### Pemodelan TSR

- Estimasi parameter

Variabel	Estimasi	SE	t-value	p-value
xt	1,57	0,57	2,76	0,01
xM1	391,33	97,13	4,03	0,00
xM2	295,28	97,38	3,03	0,00
xM3	323,03	97,63	3,31	0,00
xM4	379,68	97,88	3,88	0,00
xM5	412,27	98,13	4,20	0,00
xM6	575,71	100,05	5,75	0,00
xM7	677,42	103,68	6,53	0,00
xM8	340,88	103,93	3,28	0,00
xM9	37,12	105,90	0,35	0,73
xM10	-41,19	108,99	-0,38	0,71
xM11	27,33	103,85	0,26	0,79
xM12	416,88	99,98	4,17	0,00
xC1t	164,69	235,04	0,70	0,48
xC2t	220,33	192,63	1,14	0,25
xC3t	920,67	166,70	5,52	0,00
xC4t	1940,23	166,78	11,63	0,00
xC1tp1	886,05	235,74	3,76	0,00
xC2tp1	1632,63	192,41	8,49	0,00
xC3tp1	1139,88	166,63	6,84	0,00
xC4tp1	457,25	166,57	2,75	0,01


## Lampiran 6 Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)

- Pengujian residual TSR

<i>Ljung-Box test</i>			<i>LM test</i>						<i>KS test</i>	
<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>D</i>	<i>p-value</i>
12	14,78	0,25	1	0,34	0,56	7	4,31	0,74	0,14	0,01
24	29,03	0,22	2	0,33	0,85	8	5,50	0,70		
36	41,58	0,24	3	1,23	0,75	9	6,60	0,68		
48	48,26	0,46	4	1,99	0,74	10	6,57	0,77		
60	56,64	0,60	5	2,62	0,76	11	27,21	0,00		
			6	3,29	0,77	12	27,27	0,01		

### Pemodelan ARIMA

- identifikasi



- Estimasi parameter

Parameter	Estimasi	<i>p-value</i>
ar11	0,25	0,00
ar23	0,31	0,00


- Pengujian residual ARIMA

<i>Ljung-Box test</i>			<i>LM test</i>						<i>KS test</i>	
<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>D</i>	<i>p-value</i>
12	4,05	0,98	1	1,87	0,17	7	7,49	0,38	0,14	0,01
24	11,17	0,99	2	2,04	0,36	8	9,48	0,30		
36	19,67	0,99	3	2,96	0,40	9	11,02	0,27		
48	23,62	1,00	4	4,16	0,38	10	11,08	0,35		
60	27,54	1,00	5	5,12	0,40	11	24,53	0,01		
			6	5,94	0,43	12	26,69	0,01		

## Lampiran 6 *Output* Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)

### Pemodelan GARCH

- identifikasi orde GARCH



- Estimasi parameter

Parameter	Estimasi	SE	t-value	p-value
ARCH0	74008,00	8146,00	9,08	0,00
ARCH11	0,26	0,11	2,39	0,02

## L. *Outflow* Pecahan Rp 20.000,00

### Pemodelan TSR

- Estimasi parameter

Variabel	Estimasi	SE	t-value	p-value
xt	-6,50	0,69	-9,45	0,00
xM1	1295,49	117,22	11,05	0,00
xM2	1126,73	117,52	9,59	0,00
xM3	1202,90	117,82	10,21	0,00
xM4	1298,94	118,12	11,00	0,00
xM5	1358,82	118,43	11,47	0,00
xM6	1587,37	120,74	13,15	0,00
xM7	1586,86	125,12	12,68	0,00
xM8	1244,51	125,43	9,92	0,00
xM9	1147,60	127,81	8,98	0,00
xM10	1077,28	131,53	8,19	0,00
xM11	1096,85	125,32	8,75	0,00
xM12	1587,06	120,66	13,15	0,00
xC1t	-275,33	283,65	-0,97	0,33
xC2t	23,62	232,46	0,10	0,92
xC3t	1214,07	201,18	6,04	0,00
xC4t	1937,21	201,27	9,63	0,00
xC1tp1	1921,11	284,49	6,75	0,00
xC2tp1	1265,89	232,20	5,45	0,00
xC3tp1	1391,12	201,09	6,92	0,00
xC4tp1	567,22	201,01	2,82	0,01


## Lampiran 6 Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)

- Pengujian residual TSR

<i>Ljung-Box test</i>			<i>LM test</i>						<i>KS test</i>	
<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>D</i>	<i>p-value</i>
12	362,68	0,00	1	0,65	0,42	7	2,11	0,95	0,07	0,48
24	467,81	0,00	2	0,68	0,71	8	2,24	0,97		
36	475,83	0,00	3	0,68	0,88	9	2,15	0,99		
48	533,58	0,00	4	1,74	0,78	10	2,15	1,00		
60	645,61	0,00	5	1,99	0,85	11	8,04	0,71		
			6	1,99	0,92	12	8,85	0,72		

### Pemodelan ARIMA

- identifikasi



- Estimasi parameter

Parameter	Estimasi	<i>p-value</i>
ar1	-0,70	0,00
ar2	-0,51	0,00
ar3	-0,25	0,00
ar22	-0,28	0,00


- Pengujian residual ARIMA

<i>Ljung-Box test</i>			<i>LM test</i>						<i>KS test</i>	
<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>Lag</i>	$\chi^2$	<i>p-value</i>	<i>D</i>	<i>p-value</i>
12	13,12	0,36	1	7,97	0,00	7	11,12	0,13	0,10	0,10
24	27,65	0,28	2	8,96	0,01	8	12,64	0,12		
36	31,18	0,70	3	9,02	0,03	9	8,20	0,51		
48	35,14	0,92	4	9,30	0,05	10	8,82	0,55		
60	41,03	0,97	5	9,50	0,09	11	17,00	0,11		
			6	9,54	0,15	12	21,77	0,04		

## Lampiran 6 *Output* Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)

### Pemodelan GARCH

- identifikasi orde GARCH



- Estimasi parameter

Parameter	Estimasi	SE	t-value	p-value
omega	51890,00	7992,00	6,49	0,00
alpha 1	0,29	0,14	2,12	0,03

## M.Outflow Pecahan Rp 50.000,00

### Pemodelan TSR

- Estimasi parameter

Variabel	Estimasi	SE	t-value	p-value
xt	13,79	7,85	1,76	0,08
xM1	5365,31	1337,51	4,01	0,00
xM2	6816,75	1340,89	5,08	0,00
xM3	9777,61	1344,31	7,27	0,00
xM4	10175,83	1347,76	7,55	0,00
xM5	10603,16	1351,26	7,85	0,00
xM6	11982,63	1377,71	8,70	0,00
xM7	12339,53	1427,60	8,64	0,00
xM8	8973,14	1431,14	6,27	0,00
xM9	8825,75	1458,27	6,05	0,00
xM10	9032,66	1500,79	6,02	0,00
xM11	8872,49	1429,95	6,21	0,00
xM12	19760,78	1376,71	14,35	0,00
xC1t	-4815,53	3236,46	-1,49	0,14
xC2t	7387,35	2652,43	2,79	0,01
xC3t	16098,64	2295,46	7,01	0,00
xC4t	17703,38	2296,47	7,71	0,00
xC1tp1	16848,29	3246,08	5,19	0,00
xC2tp1	6161,10	2649,39	2,33	0,02
xC3tp1	1663,35	2294,47	0,73	0,47
xC4tp1	2017,76	2293,58	0,88	0,38


## Lampiran 6. Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)

- Pengujian residual TSR

<i>Ljung-Box test</i>			<i>LM test</i>						<i>KS test</i>	
Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	D	p-value
12	363,81	0,00	1	0,18	0,67	7	3,19	0,87	0,08	0,23
24	450,33	0,00	2	0,97	0,62	8	3,38	0,91		
36	460,21	0,00	3	1,78	0,62	9	3,40	0,95		
48	520,08	0,00	4	1,78	0,78	10	3,29	0,97		
60	665,79	0,00	5	2,92	0,71	11	3,47	0,98		
			6	3,06	0,80	12	5,56	0,94		

### Pemodelan ARIMA

- identifikasi



- Estimasi parameter

Parameter	Estimasi	p-value
ar1	-0,86	0,00
ar2	-0,51	0,00
ar3	-0,25	0,00
ar11	-0,15	0,01

- Pengujian residual ARIMA

<i>Ljung-Box test</i>			<i>LM test</i>						<i>KS test</i>	
Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	D	p-value
12	16,99	0,15	1	0,16	0,69	7	7,48	0,38	0,08	0,25
24	32,83	0,11	2	0,15	0,93	8	8,75	0,36		
36	40,49	0,28	3	0,25	0,97	9	9,00	0,44		
48	49,42	0,42	4	0,97	0,91	10	10,66	0,38		
60	57,41	0,57	5	2,68	0,75	11	10,74	0,47		
			6	5,58	0,47	12	14,16	0,29		

## N. Outflow Pecahan Rp 100.000,00

### Pemodelan TSR

- Estimasi parameter

Variabel	Estimasi	SE	t-value	p-value
xt	148,85	11,78	12,63	0,00
xM1	-5866,76	2007,79	-2,92	0,00



## Lampiran 6 Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (Lanjutan)


Variabel	Estimasi	SE	t-value	p-value
xM2	-3983,26	2012,87	-1,98	0,05
xM3	-1120,26	2018,00	-0,56	0,58
xM4	415,81	2023,19	0,21	0,84
xM5	402,39	2028,43	0,20	0,84
xM6	2012,53	2068,14	0,97	0,33
xM7	5208,02	2143,03	2,43	0,02
xM8	-1649,11	2148,35	-0,77	0,44
xM9	-1924,04	2189,08	-0,88	0,38
xM10	-1450,94	2252,90	-0,64	0,52
xM11	-2551,97	2146,56	-1,19	0,24
xM12	13021,94	2066,64	6,30	0,00
xC1t	-1554,07	4858,38	-0,32	0,75
xC2t	5962,32	3981,68	1,50	0,14
xC3t	18123,55	3445,81	5,26	0,00
xC4t	21085,49	3447,33	6,12	0,00
xC1tp1	15316,96	4872,83	3,14	0,00
xC2tp1	8019,37	3977,11	2,02	0,05
xC3tp1	442,61	3444,32	0,13	0,90
xC4tp1	3175,22	3442,99	0,92	0,36

- Pengujian residual TSR

Ljung-Box test			LM test						KS test	
Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	D	p-value
12	158,79	0,00	1	0,41	0,52	7	21,66	0,00	0,06	0,63
24	206,59	0,00	2	1,36	0,51	8	23,40	0,00		
36	215,18	0,00	3	1,49	0,68	9	24,40	0,00		
48	239,91	0,00	4	3,40	0,49	10	26,95	0,00		
60	308,16	0,00	5	12,99	0,02	11	33,62	0,00		
			6	15,05	0,02	12	69,55	0,00		

## Pemodelan ARIMA

- identifikasi




## Lampiran 6 Output Hasil Estimasi Parameter dan Pengujian Residual Model ARIMAX (*Lanjutan*)

- Estimasi parameter


Parameter	Estimasi	p-value
ar1	-0,92	0,00
ar2	-0,64	0,00
ar3	-0,45	0,00
ar4	-0,22	0,01
sar1	0,71	0,00

- Pengujian residual ARIMA

<i>Ljung-Box test</i>			<i>LM test</i>						<i>KS test</i>	
Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	Lag	$\chi^2$	p-value	D	p-value
12	4,87	0,96	1	0,21	0,65	7	4,53	0,72	0,08	0,32
24	18,25	0,79	2	0,20	0,91	8	4,59	0,80		
36	24,48	0,93	3	1,42	0,70	9	5,20	0,82		
48	30,58	0,98	4	3,55	0,47	10	5,30	0,87		
60	32,47	1,00	5	4,27	0,51	11	7,47	0,76		
			6	4,30	0,64	12	13,44	0,34		

**Lampiran 7** PACF Data *Inflow* dan *Outflow*

**Lampiran 7** PACF Data *Inflow* dan *Outflow* (Lanjutan)



# **Lampiran 8** Hasil Pengujian Terasvirta Data *Inflow* dan *Outflow*

a. Data *inflow* dan *outflow* dengan *lag* nya.

Data	Lag input	$\chi^2$	p-value
Y1	1	9,923	0,007
	1,11, dan 13	81,533	0,000
	1,11,12, dan 13	115,473	0,000
Y2	1	21,758	0,000
	1,10,11,12, dan 13	301,739	0,000
Y3	1	2,856	0,240
	12	9,936	0,007
	1,11,12, dan 13	117,384	0,000
Y4	1	0,251	0,882
	12	7,041	0,030
	1,11,12, dan 13	115,859	0,000
Y5	1	9,927	0,007
	1,11,12,13	171,621	0,000
	1,2,3,10,11,12, dan 13	577,617	0,000
Y6	1	5,220	0,074
	12	0,695	0,707
	1,2,3,11, dan 12	124,200	0,000
Y7	1	13,082	0,001
	12	36,497	0,000
	1,2,3,4,5,6,11, dan 12	Inf	0,000
Y8	1	57,435	0,000
	12	8,193	0,017
	1,11,12, dan 13	196,231	0,000
Y9	12	12,896	0,002
	1,11, dan 12	202,019	0,000
Y10	12	9,666	0,008
	1,11, dan 12	276,861	0,000
Y11	12	21,843	0,000
	1,11, dan 12	182,926	0,000
Y12	1	30,552	0,000
	11 dan 12	7,109	0,418
	1, 11, dan 12	53,946	0,000
Y13	11 dan 12	10,409	0,167
	1,2,3,11, dan 12	104,533	0,000
Y14	12	1,263	0,532
	1,2,3, dan 12	89,304	0,000

**Lampiran 8** Hasil Pengujian Terasvirta Data *Inflow* dan *Outflow* (Lanjutan)

b. Data *inflow* dan *outflow* dengan nilai prediksi *neural network*.

<b>Data</b>	<b><math>\chi^2</math></b>	<b><i>p-value</i></b>
Y1	0,018	0,991
Y2	0,040	0,980
Y3	4,564	0,102
Y4	0,388	0,824
Y5	0,001	0,100
Y6	0,865	0,649
Y7	0,184	0,912
Y8	0,034	0,983
Y9	2,841	0,242
Y10	0,458	0,795
Y11	0,004	0,998
Y12	2,975	0,226
Y13	0,394	0,821
Y14	0,492	0,782

## Lampiran 9 Hasil Estimasi Parameter Model NN data *Inflow* dan *Outflow*

### 1. *Inflow* Pecahan Rp 1.000,00

Prediktor	Hidden Layer		Output Layer
	Neuron 1	Neuron 2	
<i>Input layer</i>	<i>Intercept</i>	0,499	-1,2
	$Y_{t-1}$	0,008	0,01
	$t$	-0,017	0,02
	$M_1$	0,498	20,391
	$M_2$	0,592	1,233
	$M_3$	0,499	1,407
	$M_4$	0,439	1,089
	$M_5$	0,398	1,046
	$M_6$	0,244	1,057
	$M_7$	0,078	1,276
	$M_8$	0,139	1,136
	$M_9$	0,075	1,234
	$M_{10}$	0,449	0,779
	$M_{11}$	0,702	0,805
	$M_{12}$	0,593	1,049
	$V_{1,t}$	-0,083	0,218
	$V_{2,t}$	0,369	-0,83
	$V_{3,t}$	-0,2	-0,279
	$V_{4,t}$	0,3	-0,884
	$V_{1,t+1}$	0,091	18,477
	$V_{2,t+1}$	0,409	-0,328
	$V_{3,t+1}$	0,034	18,825
	$V_{4,t+1}$	0,213	0,17
<i>Hidden Layer</i>	<i>Intercept</i>		-0,917
	<i>Neuron 1</i>		2,463
	<i>Neuron 2</i>		2,028

**Lampiran 9** Hasil Estimasi Parameter Model NN Data *Inflow* dan *Outflow* (Lanjutan)

**2. Inflow Pecahan Rp 2.000,00**

Prediktor		Hidden Layer			Output Layer
		Neuron 1	Neuron 2	Neuron 3	
Input layer	Intercept	-2,16	1,62	0,37	
	$Y_{t-1}$	0,35	-0,10	-1,25	
	$t$	0,00	-0,88	0,00	
	$M_1$	1,80	-1,56	-0,82	
	$M_2$	1,86	0,95	-0,83	
	$M_3$	1,92	-1,24	-0,87	
	$M_4$	2,06	-0,02	-1,01	
	$M_5$	-16,75	0,94	0,58	
	$M_6$	0,65	1,14	0,29	
	$M_7$	0,90	0,07	0,18	
	$M_8$	-0,60	0,35	0,07	
	$M_9$	-0,28	1,63	-0,41	
	$M_{10}$	0,73	-0,79	-0,51	
	$M_{11}$	1,26	0,84	0,26	
	$M_{12}$	1,65	-0,80	-0,31	
	$V_{1,t}$	-0,65	0,64	0,04	
	$V_{2,t}$	2,35	-1,72	-0,54	
	$V_{3,t}$	-18,23	2,07	0,40	
	$V_{4,t}$	0,03	1,18	0,36	
	$V_{1,t+1}$	-0,24	-2,74	-2,22	
	$V_{2,t+1}$	1,76	-0,55	-19,67	
	$V_{3,t+1}$	2,46	0,84	-20,01	
	$V_{4,t+1}$	2,65	1,92	-1,88	
Hidden Layer	Intercept				-0,56
	Neuron 1				-2,50
	Neuron 2				0,70
	Neuron 3				-1,78



## Lampiran 9 Hasil Estimasi Parameter Model NN Data *Inflow* dan *Outflow* (Lanjutan)

### 3. *Inflow* Pecahan Rp 5.000,00

Prediktor	Hidden Layer		Output Layer
	Neuron 1	Neuron 2	
<i>Input layer</i>	<i>Intercept</i>	-0,28	-0,61
	$Y_{t-12}$	-3,83	0,32
	$t$	-0,01	0,00
	$M_1$	-17,76	-0,77
	$M_2$	-1,72	-18,68
	$M_3$	-1,65	-18,58
	$M_4$	19,29	0,27
	$M_5$	20,18	0,23
	$M_6$	19,51	0,20
	$M_7$	19,14	0,18
	$M_8$	3,34	0,20
	$M_9$	9,73	0,15
	$M_{10}$	2,58	-0,24
	$M_{11}$	-7,15	-0,90
	$M_{12}$	-1,68	-1,11
	$V_{1,t}$	0,62	0,86
	$V_{2,t}$	-5,22	0,17
	$V_{3,t}$	2,27	0,01
	$V_{4,t}$	17,41	-0,15
	$V_{1,t+1}$	-14,03	0,74
	$V_{2,t+1}$	-20,33	0,11
	$V_{3,t+1}$	0,82	0,77
	$V_{4,t+1}$	-30,16	0,27
<i>Hidden Layer</i>	<i>Intercept</i>		1,64
	<i>Neuron 1</i>		-0,88
	<i>Neuron 2</i>		2,46

**Lampiran 9** Hasil Estimasi Parameter Model NN Data *Inflow* dan *Outflow* (Lanjutan)

**4. Inflow Pecahan Rp 10.000,00**

Prediktor	Hidden Layer		Output Layer
	Neuron 1		
Input layer	Intercept	0,51	
	$Y_{t-12}$	-0,14	
	$t$	0,00	
	$M_1$	0,49	
	$M_2$	0,51	
	$M_3$	0,51	
	$M_4$	0,54	
	$M_5$	0,56	
	$M_6$	0,58	
	$M_7$	0,57	
	$M_8$	0,49	
	$M_9$	0,53	
	$M_{10}$	0,52	
	$M_{11}$	0,54	
	$M_{12}$	0,56	
	$V_{1,t}$	-0,11	
	$V_{2,t}$	-0,13	
	$V_{3,t}$	-0,05	
	$V_{4,t}$	0,12	
	$V_{1,t+1}$	0,03	
	$V_{2,t+1}$	-0,06	
	$V_{3,t+1}$	-0,14	
	$V_{4,t+1}$	-0,36	
Hidden Layer	Intercept		6,99
	Neuron 1		-9,55

## Lampiran 9 Hasil Estimasi Parameter Model NN Data *Inflow* dan *Outflow* (Lanjutan)

### 5. *Inflow* Pecahan Rp 20.000,00

Prediktor	Hidden Layer			Output Layer
	Neuron 1	Neuron 2	Neuron 3	
<i>Input layer</i>	<i>Intercept</i>	0,02	-0,94	-0,02
	$Y_{t-1}$	0,02	-2,07	-0,49
	$Y_{t-2}$	-0,97	0,10	-0,12
	$Y_{t-3}$	-0,98	-0,35	-0,03
	$Y_{t-10}$	-0,67	-0,10	0,02
	$Y_{t-11}$	-0,85	-1,05	-0,18
	$Y_{t-12}$	-1,11	1,19	-0,23
	$Y_{t-13}$	-0,31	-1,07	0,28
	$t$	0,54	0,61	0,00
	$M_1$	5,60	-5,57	0,31
	$M_2$	-0,52	-0,18	0,65
	$M_3$	0,97	-3,28	0,65
	$M_4$	-1,14	3,38	0,67
	$M_5$	4,86	-5,04	0,67
	$M_6$	6,31	-6,03	0,73
	$M_7$	6,60	-6,69	0,63
	$M_8$	-2,84	2,74	0,43
	$M_9$	-4,17	2,57	0,71
	$M_{10}$	-2,41	-9,84	0,81
	$M_{11}$	1,25	-1,95	0,70
	$M_{12}$	2,84	-2,53	1,09
	$V_{1,t}$	7,56	-15,06	-0,68
	$V_{2,t}$	-1,32	-0,25	-0,28
	$V_{3,t}$	-1,41	-1,50	0,26
	$V_{4,t}$	2,87	-12,84	1,58
	$V_{1,t+1}$	-13,54	-1,10	-0,42
	$V_{2,t+1}$	1,09	0,43	-0,29
	$V_{3,t+1}$	2,85	-6,32	-0,81
	$V_{4,t+1}$	-18,39	0,36	-1,23
<i>Hidden Layer</i>	<i>Intercept</i>			-0,08
	<i>Neuron 1</i>			2,02
	<i>Neuron 2</i>			-1,35
	<i>Neuron 3</i>			-1,64

**Lampiran 9** Hasil Estimasi Parameter Model NN Data *Inflow* dan *Outflow* (Lanjutan)

**6. Inflow Pecahan Rp 50.000,00**

Prediktor		Hidden Layer		Output Layer
		Neuron 1	Neuron 2	
Input layer	Intercept	0,78	0,31	
	$Y_{t-1}$	0,94	0,03	
	$Y_{t-2}$	0,13	-0,06	
	$Y_{t-3}$	-0,06	-0,04	
	$Y_{t-11}$	1,59	0,04	
	$Y_{t-12}$	-0,64	0,00	
	$t$	-0,05	0,00	
	$M_1$	-0,15	0,58	
	$M_2$	-0,42	0,76	
	$M_3$	0,73	0,93	
	$M_4$	0,75	0,94	
	$M_5$	0,73	0,91	
	$M_6$	0,29	0,91	
	$M_7$	0,87	0,83	
	$M_8$	0,94	0,87	
	$M_9$	1,19	1,01	
	$M_{10}$	2,81	1,04	
	$M_{11}$	1,97	1,01	
	$M_{12}$	-1,54	1,03	
	$V_{1,t}$	2,61	-0,50	
	$V_{2,t}$	-22,95	-0,65	
	$V_{3,t}$	-2,81	-0,37	
	$V_{4,t}$	-3,24	0,12	
	$V_{1,t+1}$	0,18	-0,09	
	$V_{2,t+1}$	2,98	0,58	
	$V_{3,t+1}$	4,51	-0,12	
	$V_{4,t+1}$	-23,98	-0,74	
Hidden Layer	Intercept			4,39
	Neuron 1			1,18
	Neuron 2			-5,97

## Lampiran 9 Hasil Estimasi Parameter Model NN Data *Inflow* dan *Outflow* (Lanjutan)

### 7. *Inflow* Pecahan Rp 100.000,00

Prediktor	Hidden Layer			Output Layer
	Neuron 1	Neuron 2	Neuron 3	
<i>Input layer</i>	<i>Intercept</i>	-1,02	-1,23	-1,52
	$Y_{t-1}$	-0,05	-0,64	2,03
	$t$	0,01	-0,02	0,07
	$M_1$	-0,32	3,44	-3,36
	$M_2$	-1,18	1,98	-1,44
	$M_3$	-1,36	1,80	-0,94
	$M_4$	-1,39	1,90	-1,25
	$M_5$	-1,38	1,89	-1,13
	$M_6$	-1,36	1,95	-1,20
	$M_7$	-1,31	1,90	-1,49
	$M_8$	-1,30	1,95	-1,52
	$M_9$	-1,43	1,92	-1,39
	$M_{10}$	-1,30	2,06	-2,19
	$M_{11}$	-1,33	1,93	-0,41
	$M_{12}$	-2,00	1,63	-0,54
	$V_{1,t}$	0,56	-0,56	-0,62
	$V_{2,t}$	1,34	1,12	0,36
	$V_{3,t}$	1,17	1,44	1,14
	$V_{4,t}$	-18,24	-0,20	-1,92
	$V_{1,t+1}$	-1,73	-0,53	0,83
	$V_{2,t+1}$	0,15	0,97	-3,29
	$V_{3,t+1}$	0,44	-0,71	20,06
	$V_{4,t+1}$	1,74	2,47	16,98
<i>Hidden Layer</i>	<i>Intercept</i>			2,89
	<i>Neuron 1</i>			3,61
	<i>Neuron 2</i>			-1,39
	<i>Neuron 3</i>			-0,87

**Lampiran 9** Hasil Estimasi Parameter Model NN Data *Inflow* dan *Outflow* (Lanjutan)

**8. Outflow Pecahan Rp 1.000,00**

Prediktor		Hidden Layer		Output Layer
		Neuron 1	Neuron 2	
Input layer	Intercept	0,17	-0,20	
	$Y_{t-1}$	0,22	0,02	
	$Y_{t-11}$	-0,05	-0,09	
	$Y_{t-12}$	-0,52	-0,36	
	$Y_{t-13}$	0,07	0,02	
	$t$	0,02	0,01	
	$M_1$	-0,98	-0,67	
	$M_2$	-1,47	-1,08	
	$M_3$	-0,40	-0,13	
	$M_4$	-1,24	-0,89	
	$M_5$	-0,78	-0,45	
	$M_6$	-0,64	-0,35	
	$M_7$	-0,51	-0,22	
	$M_8$	-0,71	-0,39	
	$M_9$	0,04	0,32	
	$M_{10}$	0,65	0,56	
	$M_{11}$	20,35	0,65	
	$M_{12}$	-2,38	-1,99	
	$V_{1,t}$	17,72	0,96	
	$V_{2,t}$	-0,58	-0,70	
	$V_{3,t}$	1,82	0,64	
	$V_{4,t}$	-0,09	-0,79	
	$V_{1,t+1}$	19,13	0,34	
	$V_{2,t+1}$	18,67	0,36	
	$V_{3,t+1}$	-0,60	-0,53	
	$V_{4,t+1}$	-0,45	-0,41	
Hidden Layer	Intercept			-0,39
	Neuron 1			6,01
	Neuron 2			-6,55

## Lampiran 9 Hasil Estimasi Parameter Model NN Data *Inflow* dan *Outflow* (Lanjutan)

### 9. *Outflow* Pecahan Rp 2.000,00

Prediktor		Hidden Layer			Output Layer
		Neuron 1	Neuron 2	Neuron 3	
<i>Input layer</i>	<i>Intercept</i>	-0,77	2,68	2,05	
	$Y_{t-1}$	-0,82	0,22	0,69	
	$Y_{t-11}$	-0,14	-0,71	0,05	
	$Y_{t-12}$	-0,28	0,42	-0,81	
	$t$	0,44	0,37	-0,01	
	$M_1$	-1,19	-0,91	0,42	
	$M_2$	1,19	-0,32	0,49	
	$M_3$	-0,02	1,05	0,50	
	$M_4$	-0,25	0,17	0,46	
	$M_5$	-0,36	0,03	0,16	
	$M_6$	1,28	-1,01	-0,02	
	$M_7$	-0,47	0,38	0,36	
	$M_8$	0,07	-0,82	0,19	
	$M_9$	-0,27	0,36	1,28	
	$M_{10}$	1,85	0,09	1,28	
	$M_{11}$	-0,84	-0,81	0,93	
	$M_{12}$	-0,08	-2,02	0,53	
	$V_{1,t}$	-2,62	-0,74	1,54	
	$V_{2,t}$	0,89	0,38	-1,71	
	$V_{3,t}$	-0,71	1,73	0,71	
	$V_{4,t}$	1,76	-0,20	0,38	
	$V_{1,t+1}$	0,18	-1,00	-1,96	
	$V_{2,t+1}$	-0,27	-1,31	-1,56	
	$V_{3,t+1}$	0,93	-1,00	-1,28	
	$V_{4,t+1}$	-0,69	-0,57	-0,43	
<i>Hidden Layer</i>	<i>Intercept</i>				-0,07
	<i>Neuron 1</i>				1,67
	<i>Neuron 2</i>				1,09
	<i>Neuron 3</i>				-2,95

**Lampiran 9** Hasil Estimasi Parameter Model NN Data *Inflow* dan *Outflow* (Lanjutan)

**10. Outflow Pecahan Rp 5.000,00**

Prediktor		Hidden Layer		Output Layer
		Neuron 1	Neuron 2	
Input layer	Intercept	0,01	-1,92	
	$Y_{t-1}$	-0,36	-2,62	
	$Y_{t-11}$	0,14	-0,32	
	$Y_{t-12}$	0,51	1,15	
	$t$	0,00	-0,01	
	$M_1$	-0,97	0,38	
	$M_2$	-1,08	0,22	
	$M_3$	-1,08	0,16	
	$M_4$	-0,99	0,27	
	$M_5$	-0,77	0,90	
	$M_6$	-0,89	0,58	
	$M_7$	-1,27	-22,42	
	$M_8$	-1,06	0,34	
	$M_9$	-0,86	0,78	
	$M_{10}$	-1,78	-24,92	
	$M_{11}$	-1,16	0,25	
	$M_{12}$	-0,76	0,47	
	$V_{1,t}$	0,08	-15,48	
	$V_{2,t}$	1,05	6,84	
	$V_{3,t}$	0,19	-0,18	
	$V_{4,t}$	0,45	-20,90	
	$V_{1,t+1}$	1,34	1,68	
	$V_{2,t+1}$	1,44	2,66	
	$V_{3,t+1}$	0,67	2,55	
	$V_{4,t+1}$	0,98	25,43	
Hidden Layer	Intercept			0,64
	Neuron 1			3,40
	Neuron 2			-2,14



**Lampiran 9** Hasil Estimasi Parameter Model NN Data *Inflow* dan *Outflow* (Lanjutan)

**11. Outflow Pecahan Rp 10.000,00**

Prediktor	Hidden Layer		Output Layer
	Neuron 1	Neuron 2	
<i>Input layer</i>	<i>Intercept</i>	-0,23	0,40
	$Y_{t-1}$	-0,35	-2,69
	$Y_{t-11}$	0,05	0,08
	$Y_{t-12}$	0,14	0,25
	$t$	0,00	0,00
	$M_1$	-1,22	-2,38
	$M_2$	-1,51	-2,83
	$M_3$	-1,39	-2,95
	$M_4$	-1,28	-2,65
	$M_5$	-1,11	-2,11
	$M_6$	-1,37	-21,52
	$M_7$	-0,86	-1,58
	$M_8$	-1,23	-2,23
	$M_9$	-1,49	-2,91
	$M_{10}$	-1,92	-3,52
	$M_{11}$	-2,12	-3,59
	$M_{12}$	-1,19	-2,91
	$V_{1,t}$	-16,77	2,80
	$V_{2,t}$	-19,96	-14,94
	$V_{3,t}$	1,32	1,96
	$V_{4,t}$	1,08	-15,98
	$V_{1,t+1}$	1,42	2,25
	$V_{2,t+1}$	1,72	3,51
	$V_{3,t+1}$	1,28	2,43
	$V_{4,t+1}$	0,39	0,76
<i>Hidden Layer</i>	<i>Intercept</i>		2,00
	<i>Neuron 1</i>		5,42
	<i>Neuron 2</i>		-2,80

**Lampiran 9** Hasil Estimasi Parameter Model NN Data *Inflow* dan *Outflow* (Lanjutan)

**12. Outflow Pecahan Rp 20.000,00**

Prediktor		Hidden Layer	Output
		Neuron 1	Layer
Input layer	Intercept	-1,38	
	$Y_{t-11}$	0,20	
	$Y_{t-12}$	0,09	
	$t$	0,00	
	$M_1$	-0,01	
	$M_2$	-0,22	
	$M_3$	-0,15	
	$M_4$	-0,11	
	$M_5$	-0,17	
	$M_6$	-0,02	
	$M_7$	-0,03	
	$M_8$	-0,23	
	$M_9$	-0,41	
	$M_{10}$	-0,75	
	$M_{11}$	-0,80	
	$M_{12}$	0,02	
	$V_{1,t}$	0,14	
	$V_{2,t}$	0,22	
	$V_{3,t}$	0,75	
	$V_{4,t}$	1,02	
	$V_{1,t+1}$	0,91	
	$V_{2,t+1}$	0,51	
	$V_{3,t+1}$	0,32	
	$V_{4,t+1}$	-0,14	
Hidden Layer	Intercept		11,44
	Neuron 1		12,50

**Lampiran 9** Hasil Estimasi Parameter Model NN Data *Inflow* dan *Outflow* (Lanjutan)

**13. Outflow Pecahan Rp 50.000,00**

Prediktor	Hidden Layer		Output Layer
	Neuron 1		
Input layer	Intercept	-0,26	
	$Y_{t-11}$	-0,02	
	$Y_{t-12}$	-0,02	
	$t$	0,00	
	$M_1$	0,46	
	$M_2$	0,46	
	$M_3$	0,43	
	$M_4$	0,43	
	$M_5$	0,44	
	$M_6$	0,43	
	$M_7$	0,42	
	$M_8$	0,45	
	$M_9$	0,45	
	$M_{10}$	0,44	
	$M_{11}$	0,47	
	$M_{12}$	0,35	
	$V_{1,t}$	0,06	
	$V_{2,t}$	-0,06	
	$V_{3,t}$	-0,12	
	$V_{4,t}$	-0,13	
	$V_{1,t+1}$	-0,11	
	$V_{2,t+1}$	-0,03	
	$V_{3,t+1}$	0,05	
	$V_{4,t+1}$	0,03	
Hidden Layer	Intercept		2,66
	Neuron 1		-16,96

**Lampiran 9** Hasil Estimasi Parameter Model NN Data *Inflow* dan *Outflow* (Lanjutan)

**14. Outflow Pecahan Rp 100.000,00**

Prediktor		Hidden Layer					Output Layer
		Neuron 1	Neuron 2	Neuron 3	Neuron 4	Neuron 5	
Input layer	Intercept	-0,12	-1,81	0,98	-1,25	-8,41	
	$Y_{t-11}$	-0,04	-0,10	-23,41	0,38	1,11	
	$t$	-1,51	0,01	-0,58	-1,43	0,12	
	$M_1$	-0,83	-1,67	-11,39	-1,05	-27,35	
	$M_2$	0,23	-19,43	-12,82	-0,22	-3,65	
	$M_3$	1,20	-1,47	13,69	-1,49	-2,65	
	$M_4$	-0,93	-1,12	20,32	1,17	-2,52	
	$M_5$	-0,44	-1,09	-8,18	-1,48	-3,04	
	$M_6$	-1,37	-0,75	26,02	-0,43	-3,40	
	$M_7$	-2,42	-0,75	-5,76	-1,05	-11,64	
	$M_8$	-0,18	-1,08	18,51	1,52	-30,05	
	$M_9$	0,97	-1,25	12,97	0,59	-5,63	
	$M_{10}$	-0,14	-1,08	5,56	-0,22	-3,34	
	$M_{11}$	0,29	-1,13	14,87	0,71	-3,61	
	$M_{12}$	0,83	-0,02	-20,99	0,72	-4,92	
	$V_{1,t}$	0,09	-17,16	-12,24	0,44	-18,93	
	$V_{2,t}$	-0,95	0,91	-10,34	0,16	2,03	
	$V_{3,t}$	-0,90	1,31	-30,30	0,66	-2,20	
	$V_{4,t}$	0,93	1,27	-13,20	2,22	5,46	
	$V_{1,t+1}$	0,48	0,84	5,58	-1,18	27,65	
	$V_{2,t+1}$	-0,60	0,67	-19,38	-0,07	5,92	
	$V_{3,t+1}$	-2,09	-0,14	-0,22	-0,42	7,55	
	$V_{4,t+1}$	-0,67	-0,44	28,16	-0,19	9,00	
Hidden Layer	Intercept						1,82
	Neuron 1						-0,71
	Neuron 2						3,53
	Neuron 3						0,14
	Neuron 4						-0,80
	Neuron 5						0,46

**Lampiran 10** Perbandingan Kriteria dalam Pemilihan *Neuron* dan *Input Model Neural Network* Tiap Pecahan

Data	Input lag	Neuron	RMSE	MAE	MdAE	MdAPE	MAPE
Y1	1	1	12,74	10,94	11,85	72,39	75,17
		2	<b>3,49</b>	<b>3,03</b>	<b>2,57</b>	<b>18,08</b>	<b>21,07</b>
		3	40,81	22,12	9,21	60,37	175,88
		4	6,55	6,04	6,50	42,83	45,22
		5	49,84	26,58	6,61	60,74	164,00
		10	4,19	3,65	2,90	19,46	27,35
		15	48,94	32,54	12,08	92,09	234,96
	1,11, dan 13	1	7,97	6,75	6,43	40,16	45,26
		2	4,68	4,14	4,04	26,02	30,21
		3	10,79	8,54	7,46	47,49	58,08
		4	51,09	37,22	29,36	261,08	260,26
		5	62,28	41,47	8,07	68,52	266,68
		10	85,14	42,44	3,88	33,37	254,40
		15	8,06	6,44	6,34	38,06	43,49
	1,11,12, dan 13	1	5,02	4,57	3,93	24,80	30,70
		2	4,49	3,92	3,77	25,87	28,11
		3	45,76	21,25	6,24	50,30	128,55
		4	27,88	18,70	13,19	91,95	147,83
		5	53,06	34,24	12,75	111,11	218,95
		10	59,00	44,06	35,44	330,58	305,82
		15	37,58	18,66	3,78	27,91	115,36
Y2	1	1	104,22	82,49	62,07	25,93	37,09
		2	77,92	36,53	13,81	5,36	11,23
		3	<b>22,08</b>	<b>15,86</b>	<b>11,52</b>	<b>3,67</b>	<b>5,76</b>
		4	139,93	68,75	20,58	7,27	21,53
		5	41,67	27,23	24,05	6,46	11,11
		10	52,64	29,62	13,80	4,38	10,12
		15	111,47	58,81	23,47	10,73	18,58
	1,10,11,12, dan 13	1	59,35	45,90	39,47	10,76	19,71
		2	119,91	80,97	43,18	24,17	23,92
		3	80,31	50,59	33,94	10,91	16,45
		4	50,28	41,02	34,31	14,09	15,30
		5	57,56	46,22	41,39	13,59	16,26
		10	91,87	63,36	40,01	16,70	25,29
		15	56,38	39,00	28,54	9,32	13,26
Y3	1	1	157,18	95,26	51,93	11,13	12,34
		2	182,84	90,07	46,47	10,79	11,36
		3	170,84	100,35	36,84	8,41	13,01
		4	150,42	98,90	53,04	12,04	15,01
		5	342,61	225,54	133,23	23,86	29,49
		10	613,40	335,65	42,90	10,56	37,19
		15	126,57	76,68	36,03	8,17	<b>9,71</b>
	12	1	117,09	74,21	25,27	5,92	9,88
		2	<b>107,33</b>	<b>72,32</b>	46,73	10,24	10,20
		3	126,95	88,96	52,46	8,69	13,35
		4	122,64	84,65	53,47	10,54	13,49
		5	127,81	77,19	32,03	6,34	10,88
		10	174,88	95,12	23,16	6,10	13,11
		15	402,90	173,99	34,88	7,04	17,38

**Lampiran 10** Perbandingan Kriteria dalam Pemilihan *Neuron* dan *Input Model Neural Network* Tiap Pecahan (*Lanjutan*)

Data	Input lag	Neuron	RMSE	MAE	MdAE	MdAPE	MAPE
Y3	1,11,12, dan 13	1	143,88	72,71	28,50	5,71	11,95
		2	182,76	120,30	72,62	17,93	19,19
		3	157,66	96,49	59,33	10,34	15,84
		4	349,81	170,03	<b>16,94</b>	<b>4,09</b>	19,44
		5	124,67	81,55	36,04	5,44	13,36
		10	281,31	147,76	29,23	6,33	19,53
		15	243,49	154,34	53,24	11,29	22,75
Y4	1	1	259,38	148,77	76,12	10,14	14,41
		2	269,79	167,59	56,74	8,42	16,49
		3	336,93	221,66	101,54	17,26	24,59
		4	481,50	316,57	204,18	29,26	32,67
		5	236,54	149,05	61,31	10,46	14,66
		10	1661,47	1097,31	309,32	36,47	151,85
		15	439,21	224,00	39,08	6,72	19,14
	12	1	<b>156,10</b>	<b>86,24</b>	<b>34,20</b>	<b>5,59</b>	<b>9,21</b>
		2	174,71	125,43	87,54	13,68	15,23
		3	162,24	122,87	91,93	16,15	15,08
		4	198,06	110,98	40,75	7,04	11,77
		5	227,03	128,53	35,91	5,71	13,03
		10	172,41	117,18	66,72	11,06	13,48
		15	410,60	223,49	69,67	11,05	20,31
	1,11,12, dan 13	1	333,00	227,83	84,39	14,42	24,44
		2	300,08	200,72	68,90	11,24	21,22
		3	329,78	225,45	82,83	14,15	24,15
		4	192,33	118,37	57,84	8,27	13,76
		5	349,16	204,26	68,76	14,55	20,16
		10	299,95	223,63	117,68	15,00	27,60
		15	344,88	227,43	92,06	19,40	28,35
	1	1	448,39	302,97	215,47	28,26	27,23
		2	223,46	145,21	100,49	12,99	14,73
		3	245,73	197,29	177,73	23,37	19,91
		4	144,20	115,48	103,08	12,76	12,54
		5	348,21	226,09	117,52	15,47	20,15
		10	473,43	316,72	159,82	22,92	28,43
		15	223,95	166,54	135,52	15,39	16,83
	1,11,12, dan 13	1	185,04	154,57	184,66	21,62	16,53
		2	184,47	154,09	184,51	21,52	16,49
		3	488,51	281,29	105,49	14,31	22,71
		4	334,02	214,23	83,58	11,89	19,61
		5	375,74	250,32	135,45	19,27	22,79
		10	148,42	109,79	60,04	8,50	10,85
		15	<b>101,33</b>	78,84	46,09	6,41	8,20
	1,2,3,10,11, 12, dan 13	1	104,64	90,90	93,86	10,89	11,21
		2	230,47	183,52	162,78	21,32	18,71
		3	101,54	<b>69,16</b>	<b>39,02</b>	<b>5,30</b>	<b>7,73</b>
		4	311,56	194,76	110,19	14,54	17,90
		5	235,65	168,92	115,15	16,24	15,83
		10	341,43	222,39	118,71	15,85	20,85
		15	235,18	188,21	175,15	20,89	21,55

**Lampiran 10** Perbandingan Kriteria dalam Pemilihan *Neuron* dan *Input Model Neural Network* Tiap Pecahan (*Lanjutan*)

Data	Input lag	Neuron	RMSE	MAE	MdAE	MdAPE	MAPE
Y6	1	1	7091,14	6420,26	5736,82	34,98	34,86
		2	6811,45	6191,94	5619,24	33,66	33,71
		3	3889,48	3047,54	2292,56	14,11	17,02
		4	6892,06	4767,00	2686,26	16,77	24,62
		5	<b>1829,06</b>	1481,75	1316,41	8,93	9,34
		10	4509,40	3100,82	1958,42	12,93	18,34
		15	2383,91	2078,41	2346,87	12,07	12,28
	12	1	9883,04	7280,81	5098,66	31,97	34,49
		2	4713,43	3917,75	3413,55	17,88	23,34
		3	5396,30	3511,15	2152,52	12,82	19,48
		4	2497,60	2082,79	1912,38	11,84	11,99
		5	3723,52	2754,88	2022,10	11,84	16,34
		10	3914,29	2902,17	2054,93	12,13	16,18
		15	5680,40	3948,16	2483,37	18,56	19,88
	1,2,3,11, dan 12	1	4821,99	3644,63	2504,70	16,41	17,88
		2	1836,25	<b>1462,93</b>	<b>1236,41</b>	<b>7,62</b>	<b>8,05</b>
		3	5123,77	4401,97	3612,88	24,80	23,56
		4	3276,60	2329,02	1673,99	9,83	13,75
		5	2325,51	1833,86	1370,12	8,23	9,47
		10	4405,90	3724,19	2770,39	19,04	21,50
		15	6976,89	4656,60	2639,53	17,45	23,08
Y7	1	1	8426,27	6923,90	6206,85	19,60	28,00
		2	8038,33	6466,41	5295,23	19,56	26,33
		3	6663,73	4380,81	3067,84	10,46	<b>15,04</b>
		4	4679,58	4246,77	4814,17	21,52	18,70
		5	5538,89	4756,43	4183,53	16,66	18,12
		10	5573,13	4476,83	4665,83	13,97	17,18
		15	11241,35	6251,18	3294,38	14,06	18,48
	12	1	8333,81	6876,80	5861,00	20,70	27,85
		2	7502,07	6204,79	5955,44	19,11	25,49
		3	10805,31	5878,83	<b>2239,52</b>	<b>8,75</b>	18,57
		4	12521,55	6543,67	2401,19	9,58	20,07
		5	<b>4110,75</b>	<b>3387,13</b>	2940,21	12,10	15,47
		10	10738,00	6088,55	2428,72	10,60	19,39
		15	21567,52	12196,97	5606,71	25,74	38,14
	1,2,3,4,5,6, 11, dan 12	1	11145,44	8896,23	9444,70	27,31	37,45
		2	7107,56	5936,53	6297,57	14,80	22,79
		3	6540,08	5524,20	5827,72	17,86	22,07
		4	16211,63	10072,99	7273,76	29,95	30,90
		5	28922,53	18567,88	9887,13	26,45	80,46
		10	13750,32	9936,71	7719,25	32,72	32,26
		15	21141,39	15710,22	11952,80	52,35	51,60
Y8	1	1	141,03	48,21	8,39	310,46	631,05
		2	137,54	48,67	10,58	424,29	693,68
		3	41,61	20,19	8,64	303,13	392,88
		4	8,41	7,69	9,01	347,91	316,54
		5	21,93	13,86	6,98	285,71	499,44
		10	12,86	8,92	6,77	262,76	244,51
		15	213,28	66,77	5,47	233,06	698,79

**Lampiran 10** Perbandingan Kriteria dalam Pemilihan *Neuron* dan *Input Model Neural Network* Tiap Pecahan (*Lanjutan*)

Data	Input lag	Neuron	RMSE	MAE	MdAE	MdAPE	MAPE
Y8	12	1	138,26	45,48	6,94	247,09	532,25
		2	43,72	23,43	12,89	524,19	557,20
		3	138,95	50,00	11,90	477,84	729,68
		4	138,50	49,44	11,41	458,26	711,70
		5	173,62	55,07	4,96	209,19	605,77
		10	138,58	48,98	10,87	436,62	693,34
		15	193,57	74,46	6,75	278,95	1528,29
	1, 11, 12, dan 13	1	137,82	44,95	6,15	258,49	517,13
		2	<b>3,83</b>	<b>3,30</b>	<b>3,39</b>	128,66	<b>122,43</b>
		3	65,53	31,01	7,66	294,39	817,44
		4	139,77	47,55	7,61	299,47	637,94
		5	94,42	34,30	4,60	196,09	528,73
		10	102,91	32,58	3,52	<b>102,70</b>	336,03
		15	99,84	39,51	4,49	192,26	835,78
Y9	12	1	472,67	279,24	168,25	96,42	160,48
		2	148,00	84,72	43,71	25,85	36,05
		3	214,39	107,30	42,91	31,24	37,21
		4	380,91	202,12	53,38	31,78	111,97
		5	492,52	195,31	41,85	26,43	<b>33,41</b>
		10	620,70	303,53	35,20	32,80	237,55
		15	586,45	252,21	39,42	23,80	85,45
	1, 11, dan 12	1	164,82	96,46	16,86	12,51	65,22
		2	102,32	60,59	16,44	9,46	62,69
		3	<b>101,73</b>	<b>58,21</b>	<b>12,96</b>	<b>8,14</b>	61,22
		4	339,13	161,49	38,95	34,85	36,11
		5	103,66	63,05	16,51	9,81	62,93
		10	341,00	160,58	36,61	18,70	83,05
		15	406,34	183,64	36,42	31,03	78,83
Y10	12	1	656,24	327,09	85,98	40,83	52,33
		2	1127,73	528,65	116,70	31,91	101,34
		3	897,22	433,74	119,95	56,68	65,12
		4	1184,24	499,80	87,56	25,69	70,65
		5	1243,12	682,74	210,57	76,96	254,70
		10	899,95	479,78	114,79	46,06	122,56
		15	1027,22	498,14	146,14	47,28	87,77
	1, 11, dan 12	1	224,87	127,84	<b>44,09</b>	17,54	38,11
		2	<b>219,54</b>	<b>126,58</b>	74,60	<b>15,80</b>	<b>28,82</b>
		3	339,68	189,92	56,66	19,21	30,61
		4	439,08	204,28	93,29	32,26	46,54
		5	773,52	387,93	84,90	26,84	152,37
		10	727,63	390,73	141,12	47,28	86,11
		15	799,49	374,30	65,77	23,16	102,13
Y11	12	1	318,64	214,25	120,43	<b>18,31</b>	55,72
		2	318,71	214,36	120,52	18,33	55,74
		3	335,92	268,79	269,16	40,75	58,43
		4	362,85	272,98	167,61	41,00	55,79
		5	1304,36	695,13	169,23	58,57	71,11
		10	1272,12	619,65	159,10	42,53	63,91
		15	2024,24	1091,94	367,92	60,75	284,98



**Lampiran 10** Perbandingan Kriteria dalam Pemilihan *Neuron* dan *Input Model Neural Network* Tiap Pecahan (*Lanjutan*)

Data	Input lag	Neuron	RMSE	MAE	MdAE	MdAPE	MAPE
Y11	1, 11, dan 12	1	556,77	374,11	256,82	38,01	69,93
		2	<b>208,01</b>	<b>172,37</b>	<b>116,78</b>	28,12	46,88
		3	604,45	369,32	190,10	43,74	55,07
		4	476,44	324,30	212,62	33,10	96,15
		5	1020,82	482,70	176,72	38,87	44,55
		10	459,40	328,70	150,07	22,34	103,37
		15	570,55	349,57	164,38	36,48	<b>39,81</b>
Y12	1	1	944,76	558,48	234,14	51,85	64,72
		2	853,92	510,39	200,39	40,71	66,18
		3	422,83	238,52	87,07	19,91	<b>27,80</b>
		4	580,81	323,75	105,24	22,89	43,70
		5	745,31	359,84	95,73	19,61	32,29
		10	1061,65	617,96	255,89	52,28	134,34
	11 dan 12	15	860,63	463,94	82,25	15,31	92,96
		1	<b>350,74</b>	<b>253,45</b>	151,11	35,03	54,96
		2	839,83	487,59	101,27	21,02	102,85
		3	782,48	537,14	310,88	48,32	123,13
		4	593,21	403,76	310,88	42,58	71,73
		5	1160,31	627,09	129,36	26,15	112,27
	1, 11, dan 12	10	1348,63	687,80	210,31	55,70	79,85
		15	1110,93	506,48	174,60	53,36	53,94
		1	719,11	372,50	142,38	28,92	36,30
		2	802,68	420,05	173,80	33,93	50,35
		3	797,12	450,98	164,44	31,66	67,14
		4	777,22	370,56	<b>64,94</b>	<b>13,32</b>	34,45
	1, 11, dan 12	5	709,75	428,08	119,45	23,70	110,06
		10	546,42	350,34	175,39	27,42	36,96
		15	837,78	542,23	410,27	46,97	85,15
Y13	11 dan 12	1	<b>2199,35</b>	<b>1717,43</b>	1347,46	8,12	<b>10,12</b>
		2	4936,01	3868,51	3069,18	17,37	22,71
		3	7777,02	5029,19	4333,59	21,81	25,53
		4	4755,71	3615,80	2305,18	14,64	19,73
		5	5981,00	4272,13	2914,10	17,70	25,00
		10	4196,32	3569,44	3540,38	16,20	23,69
	1, 2, 3, 11, dan 12	15	3733,72	2914,67	2340,31	16,40	20,42
		1	3840,09	2593,04	<b>1228,70</b>	<b>7,58</b>	12,63
		2	4323,30	3487,02	3410,59	15,96	22,65
		3	7725,60	5220,97	2617,02	19,74	30,05
		4	6190,45	4569,81	3869,42	23,55	31,53
		5	3574,88	2955,99	3141,13	13,04	19,77
	12	10	6456,71	4760,89	3428,48	21,18	29,81
		15	8328,87	5276,77	2642,87	16,37	38,19
Y14	12	1	7558,17	6150,62	6886,71	14,68	22,61
		2	21886,17	13211,31	6722,53	27,49	44,41
		3	19429,29	11457,57	5852,67	24,00	35,03
		4	9611,53	5967,66	<b>2358,93</b>	20,27	19,66
		5	7189,93	5048,30	3044,36	<b>11,14</b>	<b>17,31</b>
		10	16732,58	8210,39	4695,41	20,57	22,85
		15	7400,50	5771,48	3594,41	11,72	21,63

**Lampiran 10** Perbandingan Kriteria dalam Pemilihan *Neuron* dan *Input Model Neural Network* Tiap Pecahan (*Lanjutan*)

Data	Input lag	Neuron	RMSE	MAE	MdAE	MdAPE	MAPE
Y14	1, 2, 3, dan 12	1	9557,74	7831,62	5905,59	20,29	30,90
		2	13375,05	9708,60	6489,13	20,86	37,53
		3	14376,18	11901,16	9961,88	35,41	48,75
		4	9827,11	6954,64	4022,68	11,89	26,20
		5	16280,34	11919,13	9570,51	32,90	37,66
		10	<b>6849,44</b>	<b>5208,72</b>	4051,32	14,74	20,10
		15	12461,80	8491,09	6704,77	24,52	37,53

		Hidden Layer (Neuron 1)			Output Layer		
Prediktor		$\tau=0,025$	$\tau=0,5$	$\tau=0,975$	$\tau=0,025$	$\tau=0,5$	$\tau=0,975$
<i>Input layer</i>	<i>Intercept</i>	-0,167	-0,043	1,931			
	$Z_t$	-0,001	0,011	0,248			
<i>Hidden layer</i>	<i>Intercept</i>				-118,123	3,782	-14,779
	<i>Neuron 1</i>				-1415,488	174,742	20,483

[illegible]

## Lampiran 11 Hasil Estimasi Parameter Model QRNN Data *Inflow* dan *Outflow* (Lanjutan)

Prediktor		Hidden Layer (Neuron ke-)															Output Layer
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	
		τ=0,5															
Input layer	Intercept	-1,78	0,71	-4,45	5,01	-7,44	-1,49	-15,93	-1,12	-0,21	-5,12	-3,85	1,10	-2,89	10,52	-1,94	
	Z <sub>t</sub>	2,07	1,92	2,01	-3,05	3,33	1,40	-1,21	-1,53	0,70	-2,25	3,56	1,27	2,55	-3,50	-2,07	
Hidden layer	Intercept																2,81
	Neuron 1																2,86
	Neuron 2																-3,44
	Neuron 3																2,92
	Neuron 4																-0,20
	Neuron 5																1,66
	Neuron 6																-4,00
	Neuron 7																9,08
	Neuron 8																2,45
	Neuron 9																4,12
	Neuron 10																4,31
	Neuron 11																3,98
	Neuron 12																15,49
	Neuron 13																-7,74
	Neuron 14																9,86
Neuron 15																4,19	
		τ=0,975															
Input layer	Intercept	-0,38	-4,98	-2,41	5,53	0,05	-1,71	1,08	1,93	0,16	1,33	-8,40	-7,50	1,07	5,85	-2,88	
	Z <sub>t</sub>	-0,06	6,36	3,75	0,42	1,36	0,31	-1,61	4,10	-3,18	-3,26	20,12	1,33	3,16	-3,93	2,31	
Hidden layer	Intercept																5,56
	Neuron 1																-3,05
	Neuron 2																0,68
	Neuron 3																-2,36
	Neuron 4																-2,34
	Neuron 5																5,44
	Neuron 6																-3,20

### 3. *Inflow* Pecahan Rp 5.000,00

Prediktor		Hidden Layer										Output Layer
		1	2	3	4	5	6	7	8	9	10	
Input layer	Intercept	1,95	-6,58	0,28	-1,55	1,08	2,88	-3,83	-7,30	-4,94	6,03	
	Z <sub>1</sub>	-1,64	-1,02	-1,06	-1,23	6,41	3,11	4,78	8,45	3,14	2,64	
Hidden layer	Intercept											9,07
	Neuron 1											-8,75
	Neuron 2											2,81
	Neuron 3											-1,32
	Neuron 4											-1,88
	Neuron 5											-0,83
	Neuron 6											-0,65
	Neuron 7											-7,39
	Neuron 8											4,84
	Neuron 9											-4,04
	Neuron 10											-6,65

## Lampiran 11 Hasil Estimasi Parameter Model QRNN Data *Inflow* dan *Outflow* (Lanjutan)

Prediktor		Hidden Layer										Output Layer
		1	2	3	4	5	6	7	8	9	10	
		$\tau=0,5$										
Input layer	Intercept	-7,40	17,29	-25,29	1,33	35,27	15,59	23,16	6,98	-4,37	19,77	
	$Z_i$	-17,03	-4,33	-20,09	0,59	-9,32	-3,68	17,76	16,04	-1,09	-7,46	
Hidden layer	Intercept											20,31
	Neuron 1											14,16
	Neuron 2											20,24
	Neuron 3											14,03
	Neuron 4											9,23
	Neuron 5											-6,58
	Neuron 6											-15,24
	Neuron 7											22,78
	Neuron 8											14,30
	Neuron 9											32,89
	Neuron 10											-0,94
Prediktor		Hidden Layer										Output Layer
		1	2	3	4	5	6	7	8	9	10	
		$\tau=0,975$										
Input layer	Intercept	-7,58	-0,85	-1,59	5,70	0,97	2,29	2,33	7,68	-2,77	1,17	
	$Z_i$	-4,31	2,85	-1,38	-1,86	2,95	-4,15	-1,14	-5,79	2,56	-0,81	
Hidden layer	Intercept											6,79
	Neuron 1											7,72
	Neuron 2											0,94
	Neuron 3											-5,89
	Neuron 4											-4,23
	Neuron 5											-1,14
	Neuron 6											2,85
	Neuron 7											4,05
	Neuron 8											2,60
	Neuron 9											8,22
	Neuron 10											3,25

## Lampiran 11 Hasil Estimasi Parameter Model QRNN Data *Inflow* dan *Outflow* (Lanjutan)

### 4. *Inflow* Pecahan Rp 10.000,00

Prediktor	<i>Hidden Layer</i>					<i>Output Layer</i>	<i>Hidden Layer</i>					<i>Output Layer</i>	<i>Hidden Layer</i>					<i>Output Layer</i>
	1	2	3	4	5		1	2	3	4	5		1	2	3	4	5	
	$\tau=0,025$						$\tau=0,5$						$\tau=0,975$					
<i>Input layer</i>	<i>Intercept</i>	-1,59	1,72	-12,71	3,27	-3,73	327,12	-32,49	328,09	373,74	-0,03	-1,72	-83,63	33,14	-100,56	-13,45		
	$Z_t$	-2,72	4,61	0,26	1,00	0,38	53,34	7,55	-82,85	-28,81	-0,01	1,29	13,27	39,33	148,20	-2,77		
<i>Hidden layer</i>	<i>Intercept</i>					-13,56					273,18						51,90	
	<i>Neuron 1</i>					6,05					194,43						1,85	
	<i>Neuron 2</i>					3,14					114,42						21,86	
	<i>Neuron 3</i>					-11,54					114,13						0,59	
	<i>Neuron 4</i>					20,85					-469,46						0,23	
	<i>Neuron 5</i>					16,75					-138,55						28,25	

### 5. *Inflow* Pecahan Rp 20.000,00

Prediktor		<i>Hidden Layer (Neuron 1)</i>	<i>Output Layer</i>	<i>Hidden Layer (Neuron 1)</i>	<i>Output Layer</i>	<i>Hidden Layer (Neuron 1)</i>	<i>Output Layer</i>
		$\tau=0,025$		$\tau=0,5$		$\tau=0,975$	
<i>Input layer</i>	<i>Intercept</i>	-0,23		0,03		0,00	
	$Z_t$	0,00		0,28		-0,12	
<i>Hidden layer</i>	<i>Intercept</i>		-73,88		-10,12		25,71
	<i>Neuron 1</i>		-654,87		72,75		435,34

### 6. *Inflow* Pecahan Rp 50.000,00

Prediktor		<i>Hidden Layer</i>	<i>Output Layer</i>	<i>Hidden Layer</i>	<i>Output Layer</i>	<i>Hidden Layer</i>	<i>Output Layer</i>
		1	2	1	2	1	2
		$\tau=0,025$		$\tau=0,5$		$\tau=0,975$	
<i>Input layer</i>	<i>Intercept</i>	-0,21	-1,27	3,04	1,62	-1,23	-5,73
	$Z_t$	-0,14	0,72	3,91	-0,77	0,84	-1,86

## Lampiran 11 Hasil Estimasi Parameter Model QRNN Data *Inflow* dan *Outflow* (Lanjutan)

Prediktor	Hidden Layer		Output Layer	Hidden Layer		Output Layer	Hidden Layer		Output Layer
	1	2		1	2		1	2	
	$\tau=0,025$			$\tau=0,5$			$\tau=0,975$		
Hidden layer									
Intercept			1,04			1,62			-8,14
Neuron 1			-2,15			0,46			2,72
Neuron 2			3,11			-2,97			-10,10

### 7. *Inflow* Pecahan Rp 100.000,00

Prediktor		Hidden Layer										Output Layer
		1	2	3	4	5	6	7	8	9	10	
		τ=0,025										
Input layer	Intercept	2,30	-6,26	1,63	-0,47	1,97	5,98	-3,54	-5,66	-4,43	0,24	
	Z <sub>t</sub>	-0,51	0,28	-0,05	0,80	0,10	-5,11	4,73	-0,92	4,26	-0,10	
Hidden layer	Intercept											6,18
	Neuron 1											-3,29
	Neuron 2											2,23
	Neuron 3											-2,22
	Neuron 4											0,64
	Neuron 5											-2,84
	Neuron 6											-4,01
	Neuron 7											2,27
	Neuron 8											-2,85
	Neuron 9											-5,99
Neuron 10											-3,53	





## Lampiran 11 Hasil Estimasi Parameter Model QRNN Data *Inflow* dan *Outflow* (Lanjutan)

### 8. *Outflow* Pecahan Rp 1.000,00

Prediktor		Hidden Layer					Hidden Layer					Hidden Layer				
		1	2	3	4	5	1	2	3	4	5	1	2	3	4	5
		$\tau=0,025$					$\tau=0,025$					$\tau=0,975$				
<i>Input layer</i>	<i>Intercept</i>	1,43	0,29	1,65	-3,99	3,53	27,67	-94,66	27,40	0,53	54,12	0,70	-1,58	0,273	-1,47	0,94
	$Z_t$	-1,25	-1,06	0,03	7,849	0,75	90,26	-98,98	89,41	-0,28	-12,08	5,13	3,85	4,20	0,62	-0,79
<i>Hidden layer</i>	<i>Intercept</i>					3,38						33,86				2,46
	<i>Neuron 1</i>					3,14						51,11				3,73
	<i>Neuron 2</i>					5,42						23,12				0,67
	<i>Neuron 3</i>					-3,86						-51,05				-4,09
	<i>Neuron 4</i>					0,40						-7,24				4,28
	<i>Neuron 5</i>					1,47						-8,91				1,00

### 9. *Outflow* Pecahan Rp 2.000,00

Prediktor		Hidden Layer			Output Layer	Hidden Layer			Output Layer	Hidden Layer			Output Layer
		1	2	3		1	2	3		1	2	3	
		$\tau=0,025$				$\tau=0,5$				$\tau=0,975$			
<i>Input layer</i>	<i>Intercept</i>	0,18	-28,00	-9,32		0,31	-90,25	-181,26		1,14	-109,10	35,83	
	$Z_t$	0,06	6,19	-8,58		-0,04	-337,36	-269,91		0,16	32,94	48,62	
<i>Hidden layer</i>	<i>Intercept</i>				4,97				104,53				82,96
	<i>Neuron 1</i>				36,09				-51,86				18,25
	<i>Neuron 2</i>				-0,64				0,00				0,13
	<i>Neuron 3</i>				9,01				96,59				-92,11

Prediktor		Hidden Layer (Neuron 1)	Output Layer	Hidden Layer (Neuron 1)	Output Layer	Hidden Layer (Neuron 1)	Output Layer
		$\tau=0,025$		$\tau=0,5$		$\tau=0,975$	
Input layer	Intercept	-0,13		0,04		0,03	
	$Z_i$	0,00		-0,09		0,04	
Hidden layer	Intercept		-190,68		2,30		-1,21
	Neuron 1		-3046,19		54,17		76,44

[illegible]

### Lampiran 11 Hasil Estimasi Parameter Model QRNN Data *Inflow* dan *Outflow* (Lanjutan)

Prediktor		Hidden Layer														Output Layer
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
		$\tau=0,025$														
	Neuron 11															-2,89
	Neuron 12															0,90
	Neuron 13															1,38
	Neuron 14															1,42
	Neuron 15															0,96
Prediktor		Hidden Layer														Output Layer
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
		$\tau=0,5$														
Input layer	Intercept	-3,50	-4	-2,17	5,35	1	-0,88	-9,87	-4,93	3,42	-2,56	2,98	5,84	1,96	-2,53	-2,98
	$Z_i$	0,72	2	-3,03	-2,22	-1	0,07	-1,82	3,24	0,13	-2,28	-7,12	1,34	1,19	6,01	1,39
Hidden layer	Intercept															8,95
	Neuron 1															3,76
	Neuron 2															-4,89
	Neuron 3															-5,52
	Neuron 4															-2,79
	Neuron 5															1,04
	Neuron 6															-8,19
	Neuron 7															5,32
	Neuron 8															4,61
	Neuron 9															9,66
	Neuron 10															3,67
	Neuron 11															4,35
	Neuron 12															-5,82
	Neuron 13															-7,95
	Neuron 14															6,11
	Neuron 15															-1,70

Prediktor		Hidden Layer															Output Layer
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	
		τ=0,025															
Input layer	Intercept	-0,02	-4,43	0,89	-0,28	0,72	0,09	0,43	3,75	6,58	-1,40	-0,51	-5,09	-5,25	9,04	-0,42	
	Z <sub>i</sub>	-1,80	0,35	-0,19	-6,86	-16,21	0,05	-11,32	4,49	0,39	2,99	-0,96	0,38	-8,39	7,73	-4,51	
Hidden layer	Intercept																9,22
	Neuron 1																-1,16
	Neuron 2																0,50
	Neuron 3																-8,64
	Neuron 4																0,79
	Neuron 5																-4,87
	Neuron 6																-3,14
	Neuron 7																7,10
	Neuron 8																5,22
	Neuron 9																-4,07
	Neuron 10																-1,41
	Neuron 11																-2,00
	Neuron 12																7,61
	Neuron 13																4,30
	Neuron 14																4,26
	Neuron 15																-3,66

## Lampiran 11 Hasil Estimasi Parameter Model QRNN Data *Inflow* dan *Outflow* (Lanjutan)

### 12. *Outflow* Pecahan Rp 20.000,00

Prediktor		<i>Hidden Layer</i> (Neuron 1)		<i>Output Layer</i>	<i>Hidden Layer</i> (Neuron 1)		<i>Output Layer</i>	<i>Hidden Layer</i> (Neuron 1)		<i>Output Layer</i>
		$\tau=0,025$			$\tau=0,5$			$\tau=0,975$		
<i>Input layer</i>	<i>Intercept</i>	-0,27			-2,85			-1,18		
	$Z_t$	0,00			0,08			1,79		
<i>Hidden layer</i>	<i>Intercept</i>			-217,50			97,50			1,75
	<i>Neuron 1</i>			-1629,91			109,55			1,99

### 13. *Outflow* Pecahan Rp 50.000,00

Prediktor		<i>Hidden Layer</i>				<i>Output Layer</i>	<i>Hidden Layer</i>				<i>Output Layer</i>	<i>Hidden Layer</i>				<i>Output Layer</i>
		1	2	3	4		1	2	3	4		1	2	3	4	
		$\tau=0,025$					$\tau=0,5$					$\tau=0,975$				
<i>Input layer</i>	<i>Intercept</i>	3,46	-0,28	-5,54	-10,96		535,74	-60,25	-0,27	-0,27		6,04	-0,55	95,95	4,14	
	$Z_t$	1,29	0,00	8,80	3,96		3454,75	20,19	2,85	2,85		6,26	0,00	-66,83	-0,19	
<i>Hidden layer</i>	<i>Intercept</i>					-2,02					1,01					57,62
	<i>Neuron 1</i>					1,20					0,22					0,76
	<i>Neuron 2</i>					-14,31					0,95					-32,56
	<i>Neuron 3</i>					0,62					-1198,07					-0,50
	<i>Neuron 4</i>					1,62					1199,48					-67,89

**Lampiran 11** Hasil Estimasi Parameter Model QRNN Data *Inflow* dan *Outflow* (*Lanjutan*)

**14. Outflow Pecahan Rp 100.000,00**

Prediktor		Hidden Layer				Output Layer	Hidden Layer				Output Layer	Hidden Layer				Output Layer
		1	2	3	4		1	2	3	4		1	2	3	4	
		$\tau=0,025$					$\tau=0,5$					$\tau=0,975$				
Input layer	Intercept	3,46	-0,28	-5,54	-10,96		535,74	-60,25	-0,27	-0,27		6,04	-0,55	95,95	4,14	
	$Z_t$	1,29	0,00	8,80	3,96		3454,75	20,19	2,85	2,85		6,26	0,00	-66,83	-0,19	
Hidden layer	Intercept					-2,02					1,01					57,62
	Neuron 1					1,20					0,22					0,76
	Neuron 2					-14,31					0,95					-32,56
	Neuron 3					0,62					-1198,07					-0,50
	Neuron 4					1,62					1199,48					-67,89

**Lampiran 12** Perbandingan Kriteria *Testing* dalam Pemilihan *Neuron Model Quantile Regression Neural Network* Tiap Pecahan

Data	Neuron	Crossing Traning	Crossing Testing	RMSE	MAE	MdAE	MdAPE	MAPE
Y1	1	0	0	<b>3,21</b>	<b>2,44</b>	<b>1,26</b>	<b>8,63</b>	<b>16,61</b>
	2	0	0	3,36	2,99	2,60	19,10	21,21
	3	0	0	3,35	3,01	2,66	19,03	21,52
	4	2	0	3,37	3,05	2,77	16,76	22,79
	5	2	0	4,74	3,99	3,62	24,14	31,45
	10	0	0	4,71	4,00	3,70	24,97	31,38
Y2	15	1	0	5,17	4,13	3,41	23,03	33,05
	1	0	0	21,93	15,95	11,89	3,64	5,81
	2	1	0	22,27	16,79	13,38	4,43	6,27
	3	1	0	<b>21,60</b>	16,16	11,26	4,19	6,06
	4	1	6	22,87	17,64	13,00	4,89	6,75
	5	1	5	21,92	16,08	12,33	3,68	5,87
Y3	10	3	1	23,64	17,14	9,90	3,88	6,42
	15	5	0	23,51	<b>15,61</b>	<b>8,84</b>	<b>3,10</b>	<b>5,68</b>
	1	0	1	99,48	71,69	47,15	10,74	10,47
	2	1	1	103,92	70,59	44,21	10,13	10,06
	3	0	1	106,99	71,01	42,84	9,64	<b>9,92</b>
	4	1	1	32944,30	9562,72	66,13	11,62	608,13
Y4	5	4	3	133,86	86,25	43,58	9,69	11,66
	10	4	2	<b>99,01</b>	<b>64,09</b>	<b>38,21</b>	<b>8,65</b>	10,78
	15	3	2	124,62	82,66	47,20	10,27	11,21
	1	0	1	166,56	91,47	32,05	5,58	8,98
	2	0	1	768,06	293,27	31,91	<b>4,60</b>	19,65
	3	1	1	13483,17	3972,93	<b>30,22</b>	5,04	212,70
Y5	4	1	3	170,57	94,83	34,87	6,20	9,20
	5	3	1	<b>161,86</b>	<b>85,58</b>	34,35	5,90	<b>8,50</b>
	10	0	2	1561,40	530,93	33,59	5,88	32,51
	15	6	5	2065,14	669,98	37,52	6,61	39,52
	1	0	0	<b>103,76</b>	<b>70,42</b>	<b>41,00</b>	<b>5,68</b>	<b>7,90</b>
	2	1	0	104,05	70,98	41,79	5,79	7,99
Y6	3	0	0	105,49	74,37	53,53	7,00	8,40
	4	1	0	104,16	72,84	47,89	6,45	8,25
	5	0	0	103,79	72,37	47,10	6,37	8,19
	10	5	0	105,29	72,52	44,40	6,12	8,18
	15	1	1	145,78	100,49	74,47	10,45	11,80
	1	0	0	1934,78	1506,69	1239,97	7,64	8,17
Y6	2	2	0	1667,78	<b>1263,03</b>	963,65	5,80	<b>6,95</b>
	3	0	0	1739,71	1342,50	888,05	5,88	7,57
	4	1	2	1686,08	1296,66	1025,96	<b>5,64</b>	7,16
	5	1	0	1680,55	1275,94	<b>868,85</b>	5,77	7,06
	10	4	4	<b>1655,48</b>	1321,38	1256,35	6,36	7,27
	15	3	3	1959,88	1600,32	1416,38	8,25	9,03



**Lampiran 12** Perbandingan Kriteria *Testing* dalam Pemilihan *Neuron Model Quantile Regression Neural Network* Tiap Pecahan (*Lanjutan*)

Data	Neuron	Crossing Traning	Crossing Testing	RMSE	MAE	MdAE	MdAPE	MAPE
Y7	1	0	0	10769,25	5894,72	<b>2131,70</b>	8,40	18,70
	2	0	0	10770,87	5894,71	2134,76	<b>8,40</b>	18,69
	3	0	0	10810,88	5891,91	2265,28	8,85	18,59
	4	3	1	13550,78	7407,68	2166,77	8,47	25,27
	5	1	0	10800,50	5893,58	2330,21	9,09	18,55
	10	0	0	<b>10673,51</b>	<b>5887,65</b>	2506,22	9,78	<b>18,51</b>
Y8	15	2	1	10915,05	5945,31	2626,24	10,21	18,59
	1	0	0	2,45	2,00	1,62	55,59	67,50
	2	3	0	2,86	2,50	2,48	95,77	92,89
	3	5	1	2,49	2,05	1,92	72,76	73,40
	4	1	0	5,25	4,96	5,48	218,47	197,47
	5	4	0	<b>2,14</b>	<b>1,69</b>	<b>1,28</b>	<b>48,03</b>	<b>57,69</b>
Y9	10	3	0	2,52	2,35	2,09	83,95	84,40
	15	1	0	5,09	4,85	5,07	189,57	186,01
	1	0	1	104,21	66,10	26,17	18,66	61,37
	2	3	0	101,55	57,70	12,19	<b>7,40</b>	60,81
	3	0	0	<b>101,25</b>	<b>56,98</b>	<b>8,46</b>	8,89	60,16
	4	1	1	104,33	65,20	18,81	10,49	64,80
Y10	5	1	2	107,48	68,78	27,61	12,37	<b>60,11</b>
	10	3	2	113,59	71,65	14,75	8,37	62,44
	15	1	3	110,90	67,53	17,90	11,19	64,43
	1	0	0	<b>218,93</b>	<b>126,43</b>	73,56	<b>15,80</b>	28,66
	2	1	1	241,87	132,61	72,78	17,10	28,56
	3	1	1	240,79	132,41	72,72	17,16	28,53
Y11	4	2	1	259,73	137,71	70,82	18,27	28,19
	5	2	3	1450,71	494,09	71,91	20,62	37,15
	10	4	2	268,66	141,24	70,93	19,74	28,63
	15	4	1	269,78	145,19	<b>67,97</b>	19,96	<b>27,42</b>
	1	4	1	208,71	170,20	117,51	28,03	44,59
	2	4	0	204,28	165,94	112,99	<b>25,79</b>	<b>44,16</b>
Y12	3	4	3	207,83	169,28	118,24	27,31	44,28
	4	4	2	209,39	169,85	142,96	28,41	44,98
	5	9	2	270,56	208,35	165,10	25,89	45,27
	10	6	3	208,04	169,36	113,19	27,47	45,08
	15	1	2	<b>203,33</b>	<b>159,04</b>	<b>98,81</b>	25,95	45,37
	1	1	2	<b>436,55</b>	<b>324,19</b>	188,56	37,06	55,56
Y12	2	0	1	542,96	370,60	197,84	33,35	56,91
	3	0	0	494,54	344,16	190,71	32,21	55,60
	4	2	0	514,86	332,76	143,53	<b>26,67</b>	<b>41,75</b>
	5	2	1	1412,36	629,49	184,63	35,96	60,70
	10	1	2	16531,76	4972,35	<b>132,14</b>	27,78	133,49
	15	3	2	1279,48	566,59	135,92	31,46	44,93

**Lampiran 12** Perbandingan Kriteria *Testing* dalam Pemilihan *Neuron Model Quantile Regression Neural Network* Tiap Pecahan (*Lanjutan*)

Data	Neuron	Crossing Traning	Crossing Testing	RMSE	MAE	MdAE	MdAPE	MAPE
Y13	1	0	0	2245,53	1867,08	1786,29	8,82	10,76
	2	0	0	<b>2108,30</b>	1690,36	1160,23	8,58	10,02
	3	1	0	2136,39	1616,54	1258,12	7,28	8,88
	4	0	0	2266,39	<b>1567,00</b>	<b>895,30</b>	<b>6,22</b>	<b>8,61</b>
	5	3	2	2536,59	1909,61	1860,46	7,47	10,32
	10	4	4	3542,52	2194,75	992,49	6,41	10,29
	15	2	5	7673,36	4171,19	1521,22	10,94	16,47
Y14	1	0	1	7213,45	5055,74	2966,98	11,06	17,30
	2	0	1	7145,30	4982,57	2857,11	10,96	17,13
	3	3	1	7180,52	5023,89	2882,90	<b>10,83</b>	17,24
	4	2	2	<b>7132,38</b>	<b>4981,52</b>	2904,52	11,15	<b>17,09</b>
	5	5	3	10855,60	6949,36	2967,40	11,44	20,74
	10	2	2	7623,75	5490,47	<b>2250,91</b>	15,09	18,63
	15	5	6	7348,82	5343,59	3111,63	14,69	18,37

### Lampiran 13 Hasil Peramalan Data *Inflow* dan *Outflow*

#### a. Peramalan dengan ARIMAX

<i>l</i>	Y1			Y2		
	Batas	Ramalan	Batas	Batas	Ramalan	Batas
	Bawah	Titik	Atas	Bawah	Titik	Atas
1	-15,37	23,36	62,08	208,73	281,67	354,62
2	-25,51	15,60	56,71	195,57	285,52	375,46
3	-22,61	18,79	60,19	194,64	292,27	389,90
4	-33,03	8,41	49,84	174,01	275,42	376,82
5	-37,09	4,35	45,79	160,94	264,25	367,56
6	-39,13	2,31	43,75	156,03	260,32	364,61
7	-30,69	10,76	52,20	173,49	278,29	383,09
8	5,07	46,51	87,95	266,82	371,88	476,94
9	-47,60	-6,16	35,28	373,35	478,54	583,74
10	-53,99	-12,55	28,89	361,48	466,75	572,01
11	-49,54	-8,09	33,35	286,45	391,76	497,06
12	-44,88	-1,63	41,61	256,79	362,11	467,44

<i>l</i>	Y3			Y4		
	Batas	Ramalan	Batas	Batas	Ramalan	Batas
	Bawah	Titik	Atas	Bawah	Titik	Atas
1	433,74	570,65	707,56	523,60	820,83	1118,05
2	346,57	484,49	622,42	432,32	667,37	902,42
3	390,52	525,00	659,47	476,34	713,04	949,75
4	318,64	457,41	596,17	347,24	597,50	847,76
5	251,66	391,86	532,06	284,86	518,47	752,07
6	302,28	436,51	570,73	296,46	539,88	783,29
7	423,28	703,17	983,05	130,34	715,77	1301,20
8	1105,09	1240,84	1376,60	1003,59	1292,09	1580,59
9	777,96	930,78	1083,61	661,84	899,69	1137,54
10	468,17	608,65	749,14	499,99	756,37	1012,74
11	394,46	528,64	662,82	454,70	695,67	936,63
12	262,74	408,66	554,58	324,18	600,96	877,73

<i>l</i>	Y5			Y6		
	Batas	Ramalan	Batas	Batas	Ramalan	Batas
	Bawah	Titik	Atas	Bawah	Titik	Atas
1	568,54	860,03	1151,52	15762,85	20292,99	24823,12
2	314,67	633,41	952,15	10154,99	14849,15	19543,32
3	293,42	619,91	946,40	8878,80	14050,12	19221,44
4	208,76	537,54	866,32	8427,46	14194,18	19960,91
5	157,21	486,68	816,15	7611,71	13705,56	19799,40
6	143,16	472,83	802,51	7185,74	13688,75	20191,76
7	725,02	1054,75	1384,49	21178,69	28056,54	34934,39
8	567,64	897,40	1227,15	9131,92	16342,40	23552,88
9	290,24	620,00	949,76	6582,70	14129,90	21677,11
10	304,72	634,48	964,25	7918,73	15781,85	23644,98
11	281,34	611,10	940,87	5341,49	13507,17	21672,85
12	176,50	506,26	836,02	2966,63	11426,78	19886,93

**Lampiran 13** Hasil Peramalan Data *Inflow* dan *Outflow*  
(*Lanjutan*)

<i>l</i>	Y7			Y8		
	Batas Bawah	Ramalan Titik	Batas Atas	Batas Bawah	Ramalan Titik	Batas Atas
1	14762,82	28004,26	41245,70	-69,31	-13,21	42,90
2	11037,26	20778,42	30519,59	-83,17	-19,81	43,55
3	9915,08	20180,87	30446,67	-85,91	-20,52	44,88
4	10289,07	20200,99	30112,90	-89,53	-23,53	42,47
5	10297,81	19401,62	28505,42	-95,85	-29,68	36,50
6	9978,25	19668,47	29358,69	227,10	293,33	359,56
7	15636,57	34020,62	52404,67	-159,64	-93,39	-27,14
8	17267,81	26954,14	36640,47	-61,51	4,74	70,99
9	9522,06	19722,23	29922,40	-65,38	0,88	67,13
10	12034,00	21276,61	30519,22	-53,22	13,04	79,29
11	9666,79	18585,02	27503,25	-85,89	-19,64	46,62
12	5136,33	16052,03	26967,73	-85,45	-19,19	47,06

<i>l</i>	Y9			Y10		
	Batas Bawah	Ramalan Titik	Batas Atas	Batas Bawah	Ramalan Titik	Batas Atas
1	115,37	191,26	267,14	-142,34	292,39	727,11
2	97,34	200,50	303,65	-77,35	353,29	783,92
3	77,89	202,48	327,07	-76,44	351,58	779,61
4	87,65	230,49	373,34	-114,00	412,86	939,73
5	131,26	290,28	449,29	47,39	681,84	1316,29
6	168,59	342,28	515,97	2318,22	2733,56	3148,90
7	53,62	240,83	428,05	343,33	819,18	1295,02
8	-231,65	-31,82	168,01	-159,06	282,08	723,22
9	-64,12	147,57	359,26	-165,10	247,67	660,44
10	-66,23	156,70	379,63	-247,95	164,42	576,79
11	-58,74	174,88	408,50	-237,47	192,42	622,32
12	14,25	258,09	501,93	-104,95	368,98	842,91

<i>l</i>	Y11			Y12		
	Batas Bawah	Ramalan Titik	Batas Atas	Batas Bawah	Ramalan Titik	Batas Atas
1	81,75	650,63	1219,51	3,95	517,96	1031,98
2	-10,53	544,54	1099,61	-100,71	423,84	948,38
3	79,60	613,28	1146,97	90,11	617,64	1145,16
4	19,76	694,65	1369,54	157,20	685,58	1213,96
5	-131,53	948,40	2028,33	-76,47	452,15	980,77
6	1506,19	2090,12	2674,05	2501,00	3029,69	3558,38
7	149,99	840,76	1531,54	97,17	625,88	1154,59
8	-21,73	540,23	1102,19	-45,15	483,57	1012,29
9	-189,65	344,74	879,13	-110,96	417,76	946,48
10	-269,55	267,09	803,73	-130,00	398,72	927,45
11	-204,82	369,27	943,36	-105,93	422,79	951,51
12	2,53	608,51	1214,48	135,62	664,35	1193,07

**Lampiran 13** Hasil Peramalan Data *Inflow* dan *Outflow* (Lanjutan)

<i>l</i>	Y13			Y14		
	Batas Bawah	Ramalan Titik	Batas Atas	Batas Bawah	Ramalan Titik	Batas Atas
1	5363,45	11366,08	17368,71	5123,72	13263,93	21404,13
2	8097,33	14158,48	20219,62	11387,13	19552,35	27717,57
3	9626,40	16074,43	22522,47	13766,20	22263,05	30759,90
4	11682,44	18487,36	25292,29	24387,26	33096,96	41806,66
5	9935,53	17291,24	24646,95	18016,30	27163,93	36311,56
6	27510,51	35116,05	42721,59	37571,58	47244,81	56918,03
7	8159,10	16122,89	24086,67	34558,37	44452,49	54346,62
8	7321,38	15604,94	23888,50	12142,87	22357,54	32572,21
9	7342,61	15951,92	24561,23	18047,38	28550,73	39054,07
10	7340,79	16232,60	25124,41	16716,37	27546,26	38376,14
11	6560,87	15749,16	24937,45	17548,57	28674,33	39800,08
12	18032,25	27324,47	36616,70	41962,74	53354,86	64746,97

b. Peramalan dengan NN

<i>l</i>	Y1	Y2	Y3	Y4	Y5	Y6	Y7
1	19,76	266,79	481,76	792,41	802,55	25619,39	47683,31
2	21,27	241,67	413,60	646,65	632,90	16102,79	25347,34
3	18,78	239,97	413,62	690,12	633,21	16576,43	21408,03
4	16,98	204,98	366,98	577,47	572,74	16574,95	21283,09
5	15,93	178,44	302,83	498,00	563,17	15647,00	21565,86
6	13,50	164,56	309,27	504,48	562,64	14011,74	22095,18
7	11,29	160,40	649,02	661,34	1321,76	32896,78	34597,47
8	13,45	456,39	1286,41	2016,20	1843,12	16652,75	9948,24
9	11,53	453,30	1104,84	1060,28	1041,82	17928,37	21496,48
10	15,17	386,45	660,11	733,95	779,54	16066,30	24320,95
11	19,92	316,14	472,43	657,93	693,69	15043,13	24064,31
12	17,45	268,62	440,59	580,57	536,99	11920,50	14183,73

<i>l</i>	Y8	Y9	Y10	Y11	Y12	Y13	Y14
1	9,54	152,56	249,05	515,99	548,04	8596,29	9517,05
2	5,89	250,48	279,02	490,62	421,66	10805,55	14699,61
3	5,70	153,04	252,81	533,49	440,08	16244,90	21529,02
4	8,55	237,47	358,89	624,58	504,62	16103,27	25528,83
5	6,39	457,00	1629,11	1036,11	1177,15	15447,52	28037,51
6	12,01	1781,22	3588,11	4485,92	5126,07	38850,13	67001,68
7	4,71	56,45	137,21	260,67	594,54	15047,42	4249,53
8	5,92	303,93	196,60	356,30	357,97	11280,41	19712,01
9	3,66	67,57	234,78	457,58	330,93	13118,90	25281,09
10	4,23	96,57	148,64	352,75	292,34	14050,07	29260,55
11	4,73	136,01	241,64	331,25	307,71	16120,82	28212,41
12	18,08	357,37	455,78	769,64	537,13	26136,17	58140,96

### Lampiran 13 Hasil Peramalan Data *Inflow* dan *Outflow* (Lanjutan)

#### c. Peramalan dengan QRNN

<i>l</i>	Y1			Y2		
	$\tau=0,025$	$\tau=0,5$	$\tau=0,975$	$\tau=0,025$	$\tau=0,5$	$\tau=0,975$
1	2,06	18,48	33,37	245,06	264,97	273,05
2	3,50	20,00	35,49	225,32	239,91	247,14
3	1,12	17,48	31,99	223,99	238,30	249,74
4	-0,59	15,67	29,45	187,53	203,88	229,29
5	-1,59	14,61	27,97	153,62	176,69	204,51
6	-3,91	12,16	24,51	139,68	163,02	196,26
7	-6,01	9,92	21,35	135,82	159,04	193,24
8	-3,95	12,11	24,45	445,00	446,36	453,32
9	-5,78	10,17	21,70	452,22	452,48	453,85
10	-2,32	13,84	26,89	348,05	384,85	437,22
11	2,21	18,64	33,60	299,18	329,11	342,17
12	-0,14	16,15	30,13	246,58	266,99	276,76

<i>l</i>	Y3			Y4		
	$\tau=0,025$	$\tau=0,5$	$\tau=0,975$	$\tau=0,025$	$\tau=0,5$	$\tau=0,975$
1	303,64	479,07	547,29	548,80	767,73	1111,80
2	290,98	408,74	525,33	473,66	628,15	830,69
3	290,99	408,75	525,34	486,67	669,77	889,90
4	278,15	331,02	483,49	459,63	561,89	770,02
5	233,36	324,22	409,77	350,55	485,77	718,29
6	240,36	347,19	418,24	365,45	491,97	721,84
7	659,35	642,44	779,01	477,04	642,22	845,51
8	1048,22	1613,02	1311,00	2389,95	2072,39	11817,24
9	1013,28	1252,17	1274,08	776,91	1024,22	1426,13
10	647,12	652,06	767,63	508,88	711,74	1037,08
11	314,84	469,42	547,26	476,17	638,94	842,01
12	313,22	436,65	541,42	460,87	564,86	772,41

<i>l</i>	Y5			Y6		
	$\tau=0,025$	$\tau=0,5$	$\tau=0,975$	$\tau=0,025$	$\tau=0,5$	$\tau=0,975$
1	660,85	798,98	968,87	25589,30	26224,95	29017,90
2	501,64	627,77	807,11	13710,62	15713,56	18398,25
3	501,93	628,08	807,40	14262,28	16156,55	18920,28
4	445,18	567,00	749,75	14260,54	16155,14	18918,63
5	436,20	557,32	740,62	13189,29	15299,00	17903,81
6	435,70	556,79	740,12	11403,12	13899,29	16199,76
7	1147,98	1321,39	1464,02	33024,00	33308,07	34280,07
8	1636,94	1843,35	1961,36	14352,08	16229,10	19005,13
9	885,36	1040,02	1197,03	15886,64	17488,92	20449,58
10	639,26	775,78	946,93	13668,54	15679,96	18358,38
11	558,69	689,14	865,06	12513,85	14766,97	17261,51
12	411,63	530,87	715,67	9329,46	12220,82	14176,48

**Lampiran 13** Hasil Peramalan Data *Inflow* dan *Outflow*  
(Lanjutan)

<i>l</i>	Y7			Y8		
	$\tau=0,025$	$\tau=0,5$	$\tau=0,975$	$\tau=0,025$	$\tau=0,5$	$\tau=0,975$
1	46333,50	48428,03	48908,70	2,34	6,89	37,85
2	24456,89	25015,19	26105,97	2,22	3,79	37,34
3	18807,37	21220,19	23917,96	2,22	3,65	37,32
4	18751,70	21106,29	23848,50	2,29	6,02	37,71
5	18884,51	21364,63	24002,34	2,22	4,18	37,41
6	19225,08	21853,58	24264,02	2,55	9,07	38,23
7	33134,16	35041,37	35562,38	2,22	3,00	37,18
8	6593,80	10268,79	12417,06	2,22	3,81	37,35
9	18849,54	21301,06	23965,69	2,23	2,73	37,05
10	22510,84	23988,78	25387,26	2,22	2,80	37,12
11	22018,52	23736,12	25233,23	2,22	3,02	37,19
12	10177,91	13851,18	17003,98	3,53	14,44	39,35

<i>l</i>	Y9			Y10		
	$\tau=0,025$	$\tau=0,5$	$\tau=0,975$	$\tau=0,025$	$\tau=0,5$	$\tau=0,975$
1	97,84	148,38	213,01	119,11	248,01	408,92
2	196,03	246,03	321,96	144,79	277,97	439,03
3	98,29	148,86	213,55	122,33	251,77	412,70
4	182,60	233,04	307,62	213,24	357,85	519,28
5	410,82	452,50	543,83	1301,70	1629,99	1794,36
6	1726,08	1789,81	1804,14	2980,21	3590,88	3752,70
7	34,70	56,13	104,32	23,26	136,21	296,54
8	251,46	299,40	380,41	74,16	195,58	356,22
9	36,88	67,19	116,65	106,88	233,75	394,58
10	51,38	96,06	149,65	33,06	147,64	308,03
11	82,67	135,31	194,36	112,76	240,60	401,47
12	307,09	352,81	438,14	296,27	454,77	616,62

<i>l</i>	Y11			Y12		
	$\tau=0,025$	$\tau=0,5$	$\tau=0,975$	$\tau=0,025$	$\tau=0,5$	$\tau=0,975$
1	245,41	499,11	827,16	225,25	518,58	1012,10
2	222,63	482,24	815,54	130,60	405,61	937,84
3	262,24	510,70	804,22	144,39	421,98	947,32
4	363,67	585,52	807,73	192,72	479,59	984,04
5	997,12	1044,04	1060,64	696,37	1104,67	1813,59
6	4693,26	4393,86	4548,30	3652,34	5830,28	3451,17
7	115,16	245,70	580,88	260,07	560,53	1045,40
8	136,85	362,59	401,99	82,90	349,28	908,21
9	195,97	458,71	730,31	62,64	325,47	896,99
10	135,43	358,51	398,23	33,74	291,62	882,25
11	127,82	332,98	394,64	45,25	305,09	887,95
12	565,29	772,77	858,39	217,07	508,76	1004,78

### Lampiran 13 Hasil Peramalan Data *Inflow* dan *Outflow* (Lanjutan)

<i>l</i>	Y13			Y14		
	$\tau=0,025$	$\tau=0,5$	$\tau=0,975$	$\tau=0,025$	$\tau=0,5$	$\tau=0,975$
1	3759,58	8285,27	14987,55	5157,42	9241,57	14258,96
2	4264,61	11386,45	17503,02	8913,63	14216,48	17695,72
3	8306,70	15079,93	20680,55	14890,63	21673,91	24457,61
4	7881,10	14917,60	20596,87	22837,41	25663,79	31228,26
5	6314,77	14345,25	20213,32	27844,70	28177,12	33062,86
6	37409,45	38007,70	46278,58	66917,65	66939,77	66937,44
7	5710,16	14158,56	19982,33	1397,21	4319,55	9872,04
8	4353,43	11733,15	17819,50	12904,90	19872,98	21341,16
9	4688,21	14688,74	18892,24	22242,48	25415,90	31011,33
10	4963,63	14219,04	19415,05	29486,80	29403,49	33901,89
11	7932,51	14937,04	20607,22	28106,63	28352,48	33182,60
12	16453,40	24251,81	34399,87	56930,48	57317,72	62486,09

d. Hasil peramalan *inflow* dan *outflow* tahun 2017 dengan metode terbaik

Bulan ke-	Inflow (miliar Rp)						
	1.000	2.000	5.000	10.000	20.000	50.000	100.000
1	14,25	249,38	582,02	774,03	904,01	26853,51	56339,90
2	14,78	239,49	510,14	745,21	768,27	17228,35	34341,99
3	11,36	238,42	481,09	733,75	699,30	16544,04	28943,46
4	13,04	216,39	406,84	594,43	621,94	16363,17	26715,61
5	9,81	169,11	391,31	531,72	591,69	17292,18	29875,87
6	9,00	124,00	216,55	380,56	460,34	8799,99	12786,37
7	13,16	1494,71	562,78	1837,78	1872,69	28595,03	76812,77
8	7,15	15,95	1613,30	2039,55	1598,78	14714,53	34448,30
9	6,12	52,13	1010,79	865,20	953,93	13978,35	28283,18
10	12,26	65,77	621,96	727,30	779,96	15954,70	32591,09
11	15,65	9,65	503,58	678,99	735,86	14739,81	32110,06
12	11,05	6,06	506,06	599,64	571,13	12936,70	23015,03

Bulan ke-	Outflow (miliar Rp)						
	1.000	2.000	5.000	10.000	20.000	50.000	100.000
1	6,92	162,48	290,86	502,33	616,26	9002,04	14793,35
2	6,21	177,80	247,73	426,07	395,73	13296,13	20591,00
3	6,04	189,96	273,83	478,21	456,91	15345,10	22838,56
4	6,12	278,83	530,69	695,20	1135,43	18036,41	34227,45
5	6,51	1316,51	874,06	2667,98	2482,61	23366,12	27493,85
6	16,19	1406,26	4424,41	4378,00	3083,01	37573,79	81750,84
7	6,27	49,91	55,06	264,96	348,90	15196,32	38982,47
8	6,63	158,54	-69,77	411,04	197,17	14326,92	23030,89
9	6,59	64,49	69,85	469,07	214,24	14336,01	30884,52
10	5,86	103,80	173,07	302,15	287,14	14390,30	23768,90
11	5,60	150,01	220,31	393,06	411,97	14739,56	36461,26
12	6,38	433,29	527,46	856,40	798,71	24392,94	59624,56



## Lampiran 14 Syntax Estimasi Parameter Model ARIMAX

```
library(tseries)
library(fgarch)
library(lmtest)
library(FinTS)

dummy<-(read.table('E:/dummy.txt', sep=';', header=TRUE))
attach(dummy)
data<-
read.table("E:/dataTA.txt", sep="\t", header=TRUE, dec=",")
attach(data)
=====
#Y1
#TSR
Yt=as.ts(Y1[1:156])
x1=as.matrix(dummy[1:156, 3:19])
x2=as.matrix(dummy[1:156, 24:27])
x=as.matrix(cbind(x1,x2))
modelTSR.Y1=lm(Yt~x-1)
resiTSR.Y1=as.ts(modelTSR.Y1$residuals)
fitsTSR.Y1=as.ts(modelTSR.Y1$fitted.values)
x1=as.matrix(dummy[157:168, 3:19])
x2=as.matrix(dummy[157:168, 24:27])
x=as.matrix(cbind(x1,x2))
new=data.frame(x=cbind(x1,x2))
foreTSR.Y1=predict(modelTSR.Y1,new, se.fit=TRUE)$fit
se.foreTSR.Y1=predict(modelTSR.Y1,new, se.fit=TRUE)$se.fit
summary(modelTSR.Y1)
resiTSR=resiTSR.Y1
#uji residual Ljung box, KS

#ARIMAX
plot(resiTSR.Y1)
par(mfrow=c(2,1))
acf(resiTSR.Y1, lag.max=48)
pacf(resiTSR.Y1, lag.max=48)

modelARIMA.Y1=arima(resiTSR.Y1, order = c(13,0,0),
transform.pars = FALSE, fixed=c
(NA,0,0,0,0,0,0,0,0,NA,NA,NA) , include.mean=FALSE)
modelARIMA.Y1
coeftest(modelARIMA.Y1)

resiARIMAX.Y1=modelARIMA.Y1$residuals
foreARIMA.Y1=predict(modelARIMA.Y1, 12)$pred
se.foreARIMA.Y1=predict(modelARIMA.Y1, 12)$se
fitsARIMA.Y1=resiTSR.Y1-resiARIMAX.Y1
resiARIMAX=resiARIMAX.Y1
```

**Lampiran 14** *Syntax* Estimasi Parameter Model ARIMAX  
(*Lanjutan*)

```
#uji residual Ljung box, KS, ARCH

#Fits gabungan
fits.Y1=fitsTSR.Y1+fitsARIMA.Y1
fitsTSR.Y1=as.vector(fitsTSR.Y1)
fits.Y1=as.vector(fits.Y1)
training.Y1=Y1[1:156]
resi.training.Y1=training.Y1-fits.Y1

#Forecast gabungan
fore.Y1=foreTSR.Y1+foreARIMA.Y1
foreTSR.Y1=as.vector(foreTSR.Y1)
fore.Y1=as.numeric(fore.Y1)
testing.Y1=Y1[157:168]
resi.testing.Y1=testing.Y1-fore.Y1

#prediksi interval
lower.Y1=fore.Y1-1.96*se.foreARIMA.Y1
upper.Y1=fore.Y1+1.96*se.foreARIMA.Y1
```



## Lampiran 16 Syntax Estimasi Parameter Model *Neural Network*

```

library(neuralnet)
library(forecast)

data=read.table('E:/dataTA.txt',sep='\t',header=TRUE,
  dec=",")
TA=data[,3:18]
meanY=matrix(0,16,1)
sdY=matrix(0,16,1)
for (i in 1:16)
{
  meanY[i]=mean(TA[1:156,i])
  sdY[i]=sd(TA[1:156,i])
}

for (i in 1:16)
{
  TA[1:156,i]<-scale(TA[1:156,i])
}
attach(TA)

dummy<-read.table('E:/dummy.txt',sep=';',header=TRUE)

#=====
#Pecahan 1000
Ytrain=Y1[2:156]
x1=as.matrix(dummy[2:156,3:19])
x2=as.matrix(dummy[2:156,24:27])
dummytrain=data.frame(cbind(x1,x2))
Yt1=Y1[1:155]
attach(dummytrain)
data=data.frame(cbind(Ytrain,Yt1,dummytrain))

rep=10
best.Yt1.Y1=list()
fits.Yt1.Y1=matrix(0,155,7)
fore.Yt1.Y1=matrix(0,12,7)
neuron=c(1,2,3,4,5,10,15)
errorke.Yt1.Y1=matrix(0,rep,7)

for (k in seq_along(neuron))
{
  besterror=100
  for ( i in 1:rep)
  {
    set.seed(100+i)

```

## Lampiran 16 Syntax Estimasi Parameter Model *Neural Network* (Lanjutan)

```

Yt1.Y1=neuralnet(Ytrain~Yt1+t+M1+M2+M3+M4+M5+M6+M7+M8+
M9+M10+M11+M12+C1t+C2t+C3t+C4t+C1tp1+C2tp1+C3tp1+
C4tp1,data=data, hidden=k,act.fct="tanh",
linear.output=TRUE, likelihood=TRUE)

if(length(Yt1.Y1$result.matrix[1,1]!=0))
{
  errorke.Yt1.Y1[i,k]=Yt1.Y1$result.matrix[1,1]
  if(Yt1.Y1$result.matrix[1,1]<besterror) {
    best.Yt1.Y1[[k]]=Yt1.Y1
    besterror=Yt1.Y1$result.matrix[1,1] }
}
}
fits.Yt1.Y1[,k]=(as.ts(unlist(best.Yt1.Y1[[k]])$
net.result))

x1=as.matrix(dummy[157:168,3:19])
x2=as.matrix(dummy[157:168,24:27])
dummytest=as.matrix(cbind(x1,x2))

#pred
Ytest=c(Ytrain,rep(0,12))
for(i in 156:167)
{
  Xtest=t(matrix(c(Ytest[i-1],as.numeric(dummytest[i-
155,])),byrow=FALSE))
  Ytest[i]=compute(best.Yt1.Y1[[k]],covariate=Xtest)$
net.result
}
fore.Yt1.Y1[,k]=Ytest[156:167]
}

```

## Lampiran 17 *Syntax* Estimasi Parameter Model *Quantile Regression Neural Network*

```
fitsNN<-read.table('E:/bestNNreal.txt',header=TRUE,dec="," ,
  sep="\t") [14:168,]
attach(fitsNN)
data<-read.table("E:/dataTA.txt",sep="\t",header=TRUE,
  dec="," ) [14:168,]
attach(data)
dataTA=data.frame(cbind(Y1,Y2,Y3,Y4,Y5,Y6,Y7,Y8,Y9,Y10,
  Y11,Y12,Y13,Y14))
attach(dataTA)
library(QRNN)
colnames(fitsNN)=colnames(dataTA)
resiNN=dataTA-fitsNN

training=dataTA[1:143,]
testing=dataTA[144:155,]
resiNNtraining=resiNN[1:143,]
resiNNtesting=resiNN[144:155,]
fitsNNtraining=fitsNN[1:143,]
fitsNNtesting=fitsNN[144:155,]

#=====

#Y_1
NN<-as.matrix(fitsNNtraining$Y1)
Ytrain<-as.matrix(training$Y1)
x=as.matrix(cbind(NN))
probs <- c(0.025, 0.50, 0.975)
QRNN.Y_1 <- fits.Y_1 <- fore.Y_1 <- list()

set.seed(100)
for(i in seq_along(probs))
{
  QRNN.Y_1[[i]]<-QRNN.fit(x=x,y=Ytrain,n.hidden=1,
    tau = probs[i],iter.max=1000,
    n.trials = 1)
  fits.Y_1[[i]]<- QRNN.predict(x, QRNN.Y_1[[i]])

  Ytest=c(Ytrain,rep(0,12))
  for(j in 144:155)
  {
    Xtest=t(matrix(c((fitsNNtesting$Y1[j-143])),
      byrow=FALSE))
    Ytest[j]=QRNN.predict(Xtest,QRNN.Y_1[[i]])
  }
  fore.Y_1[[i]]=Ytest[144:155]
}
```

## Lampiran 18 Syntax Pengujian Asumsi Residual *White Noise* dan Berdistribusi Normal

```
library(FinTS)

#Uji independen dengan Ljung Box (Residual TSR)
lags <- c(12,24,36,48,60)
hasilLB<-matrix(0,length(lags),2)
for(i in seq_along(lags))
{
  ujiLB=Box.test (resiTSR, lag = lags[i])
  hasilLB[i,1]=ujiLB$statistic
  hasilLB[i,2]=ujiLB$p.value
  rownames(hasilLB)<-lags
}
colnames(hasilLB)<-c("statistics","p.value")


#Uji efek ARCH dengan LM (H0=no ARCH effect)
lagLM <- c(1,2,3,4,5,6,7,8,9,10,11,12)
hasilLM<-matrix(0,length(lagLM),2)
for(i in seq_along(lagLM))
{
  ujiLM=ArchTest (resiTSR, lag = lagLM[i])
  hasilLM[i,1]=ujiLM$statistic
  hasilLM[i,2]=ujiLM$p.value
  rownames(hasilLM)<-lagLM
}
colnames(hasilLM)<-c("statistics","p.value")

hasilLB

hasilLM

#Uji normalitas dengan KS
ks.test(resiTSR,"pnorm",mean=mean(resiTSR),sd=sd(resiTSR))
```

## Lampiran 19 Surat Keterangan Data Instansi


**BANK INDONESIA**

**SURAT KETERANGAN**

Saya yang bertanda tangan di bawah ini, menerangkan bahwa:

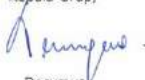
- Mahasiswa Jurusan Statistika FMIPA ITS:  
 Nama : Prilyandari Dina Saputri  
 NRP : 1313 100 020

melalui Surat No. 080848/IT2.1.1.3/TU.00.09/2017 tanggal 3 Januari 2017 telah mengajukan permohonan ijin untuk memperoleh data di instansi kami:

Nama Instansi : Bank Indonesia  
 Departemen : Departemen Pengelolaan Uang

Berupa data "Inflow dan Outflow Nasional periode bulan Januari 2003 sampai dengan Desember 2016" untuk keperluan Tugas Akhir Semester Genap 2016/2017.

- Tidak Keberatan/Keberatan\* nama instansi kami dicantumkan dalam Tugas Akhir mahasiswa Statistika yang akan disimpan di Perpustakaan ITS dan dibaca di lingkungan ITS.
- Tidak Keberatan/Keberatan\* bahwa hasil analisis Mahasiswa bersangkutan terhadap data yang diperoleh dari instansi kami dipublikasikan dalam E journal ITS yaitu Jurnal Sains dan Seni ITS.
- Semua hasil analisis terhadap data yang diperoleh dari instansi kami merupakan hasil analisis pribadi mahasiswa yang bersangkutan

Jakarta, 14 Juni 2017  
 Departemen Pengelolaan Uang  
 Kepala Grup,  
  
 Decymus  
 Direktur

\*coret yang tidak perlu

BI 100 SRT (A4B)



## BIODATA PENULIS



Penulis dengan nama lengkap Prilyandari Dina Saputri dilahirkan di Kabupaten Jember pada 4 April 1995 sebagai anak kedua dari 3 bersaudara. Penulis menempuh pendidikan formal di MIMA KH. Shiddiq Jember, SMPN 1 Jember, dan SMAN 1 Jember. Kemudian penulis diterima sebagai Mahasiswa Jurusan Statistika ITS melalui jalur SNMPTN pada tahun 2013 dengan NRP 1313100020. Selama masa perkuliahan, penulis aktif di beberapa organisasi yakni sebagai staff departemen keilmiahan HIMASTA-ITS 14/15, staff sekretaris BEM FMIPA ITS 14/15, dan sebagai sekretaris departemen keilmiahan HIMASTA-ITS 15/16, serta beberapa kepanitiaan yang diadakan oleh BEM ITS, BEM FMIPA ITS dan HIMASTA-ITS. Dibidang akademik, penulis diberi kesempatan untuk menjadi semifinalis pada beberapa lomba analisis data yang diadakan oleh STIS, IPB, UB, UII, dan ITS, yang pada akhirnya mendapatkan Juara harapan II pada Kompetisi Statistika Nasional di IPB tahun 2016 dan Juara III pada Pekan Analisis Statistik di Universitas Mulawarman tahun 2017, dan juara III dalam *College Essay Competition* di UNS tahun 2015. Pada tahun ketiga, penulis berkesempatan mendapatkan dana hibah PKM-M dan PKM-P tahun 2016. Penulis juga pernah diberi kesempatan menjadi asisten dosen mata kuliah biostatistika, teknik *sampling* dan *survey*, serta komputasi statistik. Apabila pembaca ingin memberi kritik dan saran serta diskusi lebih lanjut mengenai Tugas Akhir ini, dapat menghubungi penulis melalui email [prildisa@gmail.com](mailto:prildisa@gmail.com) atau nomor telepon 085258192004.

*(Halaman ini sengaja dikosongkan)*